

ŞCOALA DOCTORALĂ INTERDISCIPLINARĂ

Facultatea de Silvicultură şi exploatare forestiere

Jenny Magaly MOROCHO TOAZA

Precizia şi eficienţa instrumentelor portabile bazate pe tehnologia LiDAR în inventarierea arborilor

Accuracy, agreement and time efficiency of portable, LiDAR-based tools in tree inventories

REZUMAT

Conducător ştiinţific

Prof.dr. Stelian Alexandru BORZ

BRAŞOV, 2026

Inventarierea forestieră joacă un rol esențial în managementul forestier durabil, prin furnizarea de informații privind caracteristicile arborilor, precum diametrul, înălțimea, volumul și biomasa, care sunt fundamentale pentru descrierea structurii pădurii și pentru susținerea deciziilor de management (Temesgen et al., 2007; Avery & Burkhart, 2015; FAO, 2020). Precizia acestor măsurători este critică, deoarece erorile se pot propaga în estimarea biomasei și pot reduce fiabilitatea evaluărilor forestiere (Chave et al., 2014; Adhikari et al., 2024). Metodele convenționale de teren reprezintă încă cea mai utilizată abordare pentru inventarierea forestieră; cu toate acestea, ele necesită mult timp, iar acuratețea lor poate varia în funcție de operator, instrumentele utilizate și designul inventarierii (Moran & Williams, 2002; Becker & Nichols, 2011; Larjavaara & Muller-Landau, 2013; Henttonen & Kangas, 2015; Stereńczak et al., 2019; Di Cosmo, 2023).

În ultimii ani, tehnologiile LiDAR au atras o atenție tot mai mare în domeniul inventarierii forestiere datorită capacității lor de a capta informații tridimensionale privind structura vegetației (Lefsky et al., 2002; Dassot et al., 2011). Scanarea laser terestră a demonstrat o precizie ridicată în estimarea variabilelor dendrometrice, precum diametrul la înălțimea pieptului (DBH), înălțimea arborilor și structura pădurii, în diferite condiții (Liang et al., 2016; Cabo et al., 2018; Liang et al., 2018a; Liu et al., 2018). Mai recent, sistemele LiDAR portabile și mobile, inclusiv scanerle handheld și aplicațiile pentru smartphone, au apărut ca alternative practice care pot simplifica procedurile de teren și reduce timpul necesar achiziției datelor (Liang et al., 2018b; Balenović et al., 2021; Tatsumi et al., 2022; Sandim et al., 2023).

Deși studiile anterioare sugerează că aceste tehnologii pot furniza estimări fiabile ale caracteristicilor forestiere, îmbunătățind în același timp eficiența activităților de teren (Forkuo et al., 2025), performanța acestora poate varia încă în funcție de structura pădurii, caracteristicile dispozitivelor și metodele de procesare utilizate (Gülci et al., 2023; Guenther et al., 2024). Prin urmare, sunt necesare evaluări suplimentare și comparații cu metodele convenționale și cu sistemele profesionale (Gollob et al., 2021; Howie & De Stefano, 2024). Pe lângă acuratețe, evaluarea concordanței dintre metode este importantă pentru a determina dacă acestea pot fi utilizate interschimbabil în inventarierea forestiere operațională (Bland & Altman, 1999; Borz et al., 2024; Morocho et al., 2025).

Scopul acestei lucrări a fost evaluarea potențialului tehnologiilor LiDAR portabile și mobile, inclusiv al aplicațiilor pentru smartphone, pentru utilizarea în inventarierea forestieră. Lucrarea combină o analiză a stadiului actual al cunoașterii cu studii experimentale axate pe acuratețea, eficiența temporală și caracteristicile norilor de puncte generate de diferite sisteme, în diverse condiții forestiere și sezoniere.

Obiectivele specifice ale tezei au fost:

- * O1. Analiza tehnologiilor LiDAR mobile și cu cost redus utilizate în inventarierea forestieră, cu accent pe acuratețea, eficiența și potențialul acestora pentru monitorizarea forestieră multi-temporală;
- * O2. Evaluarea acurateței aplicației TreeScanner în estimarea parametrilor biometrici ai arborilor individuali în diferite ecosisteme forestiere;
- * O3. Evaluarea acurateței și eficienței temporale a aplicației TreeScanner pentru măsurarea și cartarea arborilor individuali, comparativ cu scannerul FJD Trion Model P1 în condiții de iarnă, cu accent pe estimarea suprafeței de bază și timpul de achiziție a datelor de teren;
- * O4. Analiza efectului variației sezoniere asupra estimării suprafeței de bază prin compararea sistemelor TreeScanner și FJD Trion Model P1 pe parcursul celor patru anotimpuri, evaluând separat acuratețea și timpul de achiziție pentru fiecare sistem;
- * O5. Compararea norilor de puncte generați de scannerul FJD Trion Model P1 în sezonul de iarnă și primăvară, utilizând algoritmi C2C și M3C2, pentru identificarea diferențelor structurale și asigurarea alinierii temporale între seturile de date.

CAPITOLUL 1. TEHNOLOGII LiDAR MOBILE ŞI CU COST REDUS PENTRU INVENTARIEREA FORESTIERĂ: O ANALIZĂ PRIVIND ACURATEŢEA, EFICIENŢA ŞI POTENŢIALUL DE MONITORIZARE MULTI-TEMPORALĂ

1.1. MATERIALE ŞI METODE

Revizuirea sistematică a literaturii a urmat cadrul PRISMA 2020 pentru sintetizarea cunoştinţelor existente privind performanţa tehnică şi operaţională a tehnologiilor LiDAR mobile şi cu cost redus utilizate în aplicaţii de inventariere forestieră (Page et al., 2021). Criteriile de eligibilitate au fost definite utilizând cadrul PECO, pentru a asigura relevanţa şi comparabilitatea între studii (Haddaway et al., 2018). Revizuirea a inclus studii realizate în ecosisteme forestiere utilizând sisteme LiDAR mobile sau portabile, fiind excluse studiile care au utilizat LiDAR aeropurtat sau satelitar, cu excepţia cazurilor în care a fost utilizat ca reper de referinţă.

Căutarea bibliografică a fost realizată între ianuarie şi martie 2026 utilizând patru baze de date majore: Scopus, Web of Science, IEEE Xplore şi Google Scholar. Termenii de căutare au combinat cuvinte-cheie legate de tehnologiile LiDAR, aplicaţiile de inventariere forestieră şi indicatorii de performanţă. După eliminarea duplicatelor, au rămas 680 de studii pentru etapa de selecţie. În urma evaluării titlurilor şi rezumatelor, 380 de studii au fost excluse deoarece se concentrau pe LiDAR aeropurtat, teledetecţie satelitară sau aplicaţii non-forestiere. Evaluarea integrală a textului a fost efectuată pentru 150 de articole, iar în final 56 de studii au îndeplinit toate criteriile de includere şi au fost integrate în sinteza calitativă şi cantitativă (Page et al., 2021).




Figura 1.1. Diagrama fluxului PRISMA a procesului de selecţie

Pentru fiecare studiu selectat, informaţiile au fost extrase sistematic într-o bază de date structurată, incluzând tipul tehnologiei LiDAR, ecosistemul forestier, compoziţia speciilor de arbori, dimensiunea suprafeţei de probă, numărul arborilor măsuraţi, indicatorii de acurateţe pentru diametrul la înălţimea pieptului (DBH) şi înălţime, ratele de detecţie a arborilor, eficienţa achiziţiei datelor şi condiţiile de mediu. Acest set de date a permis compararea diferitelor platforme LiDAR şi a diverselor contexte de inventariere forestieră.

Calitatea metodologică a fost evaluată utilizând o versiune adaptată a instrumentului Mixed Methods Appraisal Tool (MMAT) (Holvoet et al., 2025). Evaluarea a luat în considerare rigoarea metodologică, reprezentativitatea eşantioanelor şi fiabilitatea măsurătorilor de referinţă. Studiile au fost evaluate pe o scară cu trei niveluri, permiţând aprecierea fiabilităţii generale a bazei de dovezi incluse în revizuire.

Sinteza a combinat abordări narative şi cantitative. Rezultatele au fost grupate în funcţie de platforma tehnologică, pentru a facilita comparaţiile privind acurateţea şi eficienţa operaţională. În plus, au fost elaborate figuri şi tabele comparative pentru a ilustra tendinţele publicaţiilor, care au înregistrat o creştere semnificativă după anul 2020, precum şi pentru a sintetiza indicatorii de acurateţe utilizaţi în inventarierea forestieră şi pragurile acceptabile de precizie pentru diferite aplicaţii de inventariere.

1.2 REZULTATE

1.2.1 Caracteristicile literaturii analizate

Această revizuire sistematică a literaturii ştiinţifice a fost realizată prin efectuarea unei căutări exhaustive a studiilor publicate între anii 2015 şi 2026, perioadă identificată ca având cel mai ridicat nivel de inovare în domeniul geomatiei forestiere (Magnuson et al., 2024; Kokeza et al., 2026). Investigaţiile au urmat ghidul PRISMA (Preferred Reporting Items for Systematic Reviews and Meta-Analyses), fiind concepute pentru a asigura o metodologie transparentă şi reproductibilă în procesul de identificare şi selecţie a studiilor incluse, astfel încât să poată fi evidenţiate tendinţele dominante privind utilizarea senzorilor LiDAR mobili şi/sau cu cost redus.

Distribuţia geografică a studiilor analizate evidenţiază o concentrare clară în ţările cu sectoare forestiere şi tehnologice foarte dezvoltate. În special, Finlanda, China, Coreea de Sud, Germania şi Statele Unite apar frecvent ca centre principale de inovare pentru sistemele de personal laser scanning (PLS) şi aplicaţiile bazate pe dispozitive mobile. Această distribuţie reflectă rolul important al acestor state în dezvoltarea şi aplicarea sistemelor portabile şi a aplicaţiilor LiDAR bazate pe dispozitive mobile. Acest tipar sugerează că dezvoltarea tehnologică şi existenţa programelor de monitorizare forestieră reprezintă factori importanţi pentru implementarea acestor sisteme.

Se poate observa, de asemenea, o schimbare temporală semnificativă. Cercetările realizate între 2015 şi 2019 s-au concentrat în principal pe testarea şi validarea prototipurilor portabile voluminoase, precum şi pe dezvoltarea timpurie a algoritmilor SLAM (Tang et al., 2015; Bauwens et al., 2016; Liang et al., 2018). Începând cu anul 2020, literatura de specialitate s-a orientat puternic către accesibilitatea extinsă a acestor tehnologii, marcând o schimbare clară a tendinţelor de cercetare. Această tranziţie a fost determinată în mare măsură de integrarea senzorilor LiDAR în dispozitive comerciale larg disponibile, precum modelele iPad Pro şi iPhone Pro (Gollob et al., 2021; Výboštok et al., 2025; Kokeza et al., 2026). O creştere accentuată a numărului de studii a fost observată în anii 2021, 2022 şi 2023, în special în cazul cercetărilor care implicau sisteme portabile, platforme LiDAR bazate pe iOS şi fotogrammetrie de proximitate (Close Range Photogrammetry – CRP). Acest fapt demonstrează dezvoltarea rapidă a aplicaţiilor pentru dispozitive mobile care utilizează tehnologii LiDAR cu cost redus.

1.2.2 Evoluţia tehnologiilor de scanare mobilă

În sectorul forestier, tehnologia LiDAR a evoluat de la sisteme laser staţionare de înaltă precizie, caracterizate prin flexibilitate operaţională redusă, către platforme mobile care oferă o eficienţă operaţională sporită, cu un anumit compromis în ceea ce priveşte precizia măsurătorilor (Balenović et al., 2020). Sistemele portabile au fost dezvoltate ca soluţie pentru limitările asociate scanării laser terestre (TLS): deşi TLS oferă precizie la nivel milimetric, aceasta generează niveluri ridicate de ocluzie şi necesită un proces laborios de instalare în teren accidentat (Bauwens et al., 2016; Balenović et al., 2020; Li et al., 2025).

1.2.2.1 Cronologia transformării tehnologice

Datorită miniaturizării senzorilor şi îmbunătăţirii algoritmilor SLAM, necesari pentru funcţionarea sub coronamentul dens al pădurii, unde semnalul GNSS este instabil, procesul de digitalizare forestieră a evoluat progresiv odată cu avansul tehnologic. În perioada anterioară anului 2013, scanarea laser terestră (TLS) era dominantă, fiind caracterizată prin precizie milimetrică şi eficienţă operaţională redusă din cauza necesităţii instalării în staţii de scanare multiple (Maas et al., 2008; Brolly & Király, 2009). În anul 2013 a fost introdus sistemul ZEB1 (GeoSLAM), primul sistem portabil personal cu cap oscilant pentru scanare dinamică (Ryding et al., 2015; Bauwens et al., 2016). Ulterior, în perioada 2015–2017, progresele s-au

concentrat pe dezvoltarea sistemelor ZEB-REVO și ZEB-REVO-RT, care au integrat vizualizarea în timp real a datelor scanate și au îmbunătățit robustețea norilor de puncte (Chen et al., 2019). În 2019 a fost introdus ZEB Horizon, care a extins raza de scanare până la 100 m și a permis captarea detaliată a coronamentului superior (Gollob et al., 2020a). Perioada 2020–2021 reprezintă un moment de democratizare tehnologică, deoarece Apple Inc. a integrat senzori LiDAR de tip time-of-flight (ToF) în modelele iPad Pro și iPhone 12 Pro, facilitând colectarea datelor 3D prin intermediul dispozitivelor destinate consumatorilor (Gollob et al., 2021; Luetzenburg et al., 2021). Perioada următoare, aproximativ 2022–2023, s-a caracterizat prin extinderea și rafinarea aplicațiilor precum ForestScanner și Arboreal Forest, care integrează realitatea augmentată pentru estimarea variabilelor forestiere direct în teren (Tatsumi et al., 2022; Gülci et al., 2023; Borz et al., 2024; Howie & De Stefano, 2024). Evoluțiile recente din perioada 2024–2026 includ apariția soluțiilor eficiente din punct de vedere al costurilor, bazate pe senzori LiDAR utilizați în industria auto (de exemplu, Livox MID-360), precum și a sistemelor open-source, cum ar fi LCA-TLS. Aceste abordări urmăresc obținerea unor niveluri de precizie comparabile cu cele ale sistemelor profesionale, reducând semnificativ costurile (Balestra et al., 2024a; Výboštok et al., 2025).

1.2.2.2 Compararea tehnică: sisteme profesionale versus sisteme integrate în telefoane inteligente

Principala diferență constă în raza operațională și densitatea norilor de puncte. Sistemele profesionale portabile (ZEB Horizon, Stonex, Mandeye) pot colecta nori de puncte cu densitate ridicată pe distanțe care depășesc 100 m, în funcție de dispozitiv și condițiile de mediu (Li et al., 2022; Vandendaele et al., 2022). În schimb, senzorii LiDAR integrați în smartphone-uri (inclusiv cele mai recente modele iPhone și iPad) au o rază utilă de aproximativ 10 m și sunt adesea utilizați ca sisteme complementare sau pentru calibrarea altor sisteme profesionale portabile (Vandendaele et al., 2022; Guenther et al., 2024). În ciuda acestor diferențe privind raza operațională și densitatea punctelor, atât sistemele profesionale portabile, cât și smartphone-urile echipate cu senzori LiDAR pot utiliza tehnici avansate de comparare a norilor de puncte (precum M3C2) pentru identificarea modificărilor structurale ale pădurii în timp, oferind o precizie superioară metodelor tradiționale (Lague et al., 2013; Winiwarter et al., 2021).

1.2.3 Acuratețea dendrometrică și eficiența temporală

1.2.3.1 Performanța în măsurarea variabilelor structurale

Validarea sistemelor mobile în raport cu metodele convenționale confirmă faptul că DBH reprezintă variabila măsurată cel mai fiabil, în timp ce înălțimea totală a arborelui (TH) prezintă erori sistematice cauzate de ocluzia coronamentului. Sistemele profesionale MLS prezintă, în general, o acuratețe ridicată, cu valori RMSE sub 1,5 cm (Bauwens et al., 2016; Liang et al., 2018). În metodele tradiționale, DBH este măsurat într-un singur punct utilizând clupa forestieră (White et al., 2015); în schimb, în cazul tehnologiei LiDAR, diametrul este estimat prin algoritmi care ajustează o formă geometrică pe circumferința trunchiului, utilizând de regulă media mai multor puncte. Utilizarea dispozitivelor cu cost redus și a aplicațiilor mobile a generat niveluri de acuratețe cuprinse între 1,5 cm și 4,0 cm (Tatsumi et al., 2022; Výboštok et al., 2025). În estimarea DBH, aplicații precum ForestScanner și Arboreal Forest pot produce ușoare subestimări din cauza neregularităților scoarței care afectează eșantionarea punctelor LiDAR și a acoperirii incomplete a circumferinței trunchiului (Howie & De Stefano, 2024; Singh et al., 2024). În ceea ce privește măsurarea înălțimii, sistemele terestre, în special dispozitivele profesionale și mobile cu cost redus (mai degrabă decât aplicațiile pentru smartphone), tind să subestimeze înălțimea totală a arborilor, cu erori ce pot depăși 2 m în cazul arborilor înalți, din cauza dificultății de captare a vârfului real al coronamentului (Balestra et al., 2024a; Mîzgaciuc et al., 2025).

1.2.3.2 Analiza eficienței operaționale

Tranziția de la măsurătorile manuale tradiționale și sistemele LiDAR terestre statice către sistemele LiDAR mobile reprezintă o îmbunătățire semnificativă a productivității, reducând constant timpul necesar achiziției datelor (Li et al., 2023; Li et al., 2025). Utilizarea tabletelor și smartphone-urilor permite

colectarea mai rapidă a datelor LiDAR, reducând timpul de lucru în teren de aproximativ 2 până la 4 ori comparativ cu metodele tradiţionale, în funcţie de studiu (Proudman et al., 2022; Morocho et al., 2025). Efortul necesar măsurătorilor prin aplicaţii mobile poate fi redus până la 25,7% din timpul de lucru necesar metodei manuale în anumite cazuri (Tatsumi et al., 2022), iar mai multe studii raportează reduceri semnificative ale necesarului de forţă de muncă (Morocho et al., 2025; Kokeza et al., 2026). Studii recente care au utilizat aplicaţia TreeScanner au demonstrat că smartphone-urile pot fi de câteva ori mai rapide decât anumite sisteme profesionale personale cu cost ridicat, datorită eliminării etapelor complexe de post-procesare în laborator (Morocho et al., 2025). Această flexibilitate operaţională permite creşterea densităţii eşantionării şi asigurarea reprezentativităţii statistice a inventarelor forestiere la nivel de arboret.

1.2.3.3 Efectele sezoniere asupra calităţii datelor şi detecţiei arborilor

Variabilitatea sezonieră a condiţiilor de mediu este recunoscută ca unul dintre cei mai importanţi factori în implementarea operaţională a tehnologiilor LiDAR, în special în pădurile de foioase şi mixte, unde frunzişul influenţează fizica returului semnalului laser. Ocluzia foliară din perioada cu frunziş acţionează ca o barieră fizică ce limitează penetrarea impulsurilor către straturile inferioare ale coronamentului şi subarboret. În condiţii fără frunziş, autori precum Ko et al. (2024) raportează rate de detecţie a arborilor de până la 100%; totuşi, această valoare scade semnificativ în perioada de vegetaţie. Cercetările realizate în arborete dense (Ko et al., 2024) indică faptul că rata de detecţie se reduce la aproximativ 80–85% în condiţii cu frunziş, ceea ce implică faptul că aproximativ 18% dintre trunchiurile arborilor nu sunt detectate din cauza efectelor de ocluzie. Cu toate acestea, alţi autori, precum Wu et al. (2025a), susţin că în condiţii fără frunziş penetrarea este suficient de eficientă pentru a permite detectarea chiar şi a arborilor de dimensiuni mici.

Sezonalitatea determină, de asemenea, variaţii semnificative ale erorilor (RMSE) pentru variabilele structurale. Potrivit lui Ko et al. (2024), în perioada cu frunziş, vegetaţia din subarboret obstrucţionează baza trunchiurilor la înălţimea de 1,3 m, introducând erori în date, ceea ce reduce disponibilitatea punctelor de referinţă valide şi limitează fiabilitatea ajustării automate a diametrului, în ciuda progreselor algoritmilor de filtrare. Acurateţea estimării DBH este mai ridicată iarna (R^2 până la 0,97), în timp ce vara RMSE creşte din cauza interferenţelor produse de vegetaţia înconjurătoare (Ko et al., 2024; Singh et al., 2024; Wu et al., 2025a). Înălţimea arborilor reprezintă variabila cea mai sensibilă. Wu et al. (2025a) au observat că, în timpul verii, frunzişul împiedică fasciculul laser să atingă vârful real al arborelui, ceea ce conduce la erori de până la patru ori mai mari comparativ cu perioada de iarnă. În experimentele realizate de Ko et al. (2024), au fost obţinute valori RMSE pentru înălţime de 1,27 m în condiţii fără frunziş, comparativ cu 5,07 m în condiţii cu frunziş.

Densitatea punctelor utilizabile pe trunchi depinde de numărul impulsurilor care ating suprafaţa trunchiului fără a fi interceptate de frunze. Cercetările realizate de Khan et al. (2025) indică faptul că, pentru menţinerea erorilor DBH sub 1 cm, sunt necesare densităţi cuprinse între 600 şi 700 puncte/m³, valori dificil de atins în timpul verii sub coronamente închise. Vizibilitatea terenului este esenţială pentru generarea modelelor digitale ale terenului (DTM) precise. Ko et al. (2024) au demonstrat că majoritatea impulsurilor LiDAR ajung la sol din toamna târzie până la începutul primăverii în pădurile temperate dense de foioase, în timp ce vara un număr mult mai redus de impulsuri atinge suprafaţa terenului, ceea ce îngreunează identificarea corectă a bazei arborilor, aspect evidenţiat şi de Holvoet et al. (2025) în păduri cu structură complexă.

1.2.3.4 Perioade optime de scanare şi monitorizare hiper-temporală

Conform literaturii de specialitate, perioada cea mai favorabilă pentru colectarea datelor LiDAR în pădurile temperate este sfârşitul toamnei şi începutul iernii (de regulă luna noiembrie), când acoperirea foliară este minimă (Ko et al., 2024; Wu et al., 2025a). Dimensiunea arborilor joacă, de asemenea, un rol important: arborii foarte mici, cu DBH sub 5 cm, nu sunt, în general, capturaţi în mod fiabil de sistemele LiDAR terestre sau mobile (Ko et al., 2024). În plus, prezenţa stratului de zăpadă poate afecta determinarea cotei bazei arborelui şi a înălţimii totale, în lipsa unui model digital al terenului (DTM) de referinţă fără zăpadă. Aplicarea norilor de puncte hiper-temporali (achiziţii LiDAR frecvente în cadrul

aceluiaşi sezon de vegetaţie) permite monitorizarea modificărilor sub-anuale ale structurii arborilor şi dinamicii ramurilor. Aceasta diferă de monitorizarea multi-temporală LiDAR, în care achiziţiile sunt realizate sezonier sau anual (Bienert et al., 2024; Campos et al., 2024). Monitorizarea hiper-temporală poate permite identificarea răspunsului arborilor la factori de mediu, precum precipitaţiile şi temperatura, oferind astfel posibilitatea unei monitorizări forestiere mai detaliate.

1.2.4 Analiza multi-temporală a norilor de puncte şi dinamica forestieră

1.2.4.1 Algoritmi pentru comparaţia multi-temporală

Utilizarea tehnologiilor LiDAR mobile poate oferi o abordare transformatoare pentru inventarierea forestieră (Bienert et al., 2024; Campos, 2024). Detectarea modificărilor depinde de precizia algoritmului aplicat şi de calitatea înregistrării şi alinierii norilor de puncte între scanările succesive (Winiwarter, 2021; Shafaat et al., 2025). Dovezile ştiinţifice evidenţiază o ierarhie clară în performanţa algoritmilor de procesare directă 3D. Metoda Cloud-to-Cloud (C2C) este considerată cea mai simplă abordare, deoarece calculează distanţa euclidiană până la cel mai apropiat vecin (Lague et al., 2013). Totuşi, rezultatele arată că aceasta este foarte sensibilă la variaţiile densităţii punctelor şi la zgomotul datelor, generând distanţe fără semn, ceea ce împiedică diferenţierea între creşterea şi pierderea de biomasă (Winiwarter et al., 2021; Mîzgaciu et al., 2025). Această abordare este adecvată în principal pentru identificarea schimbărilor mari şi bruşte (de regulă >0,5 m), precum extragerea arborilor sau schimbări majore în teren (Winiwarter et al., 2021; Shafaat et al., 2025). Metoda Multiscale Model-to-Model Cloud Comparison (M3C2) este larg acceptată ca o tehnică foarte fiabilă pentru monitorizarea pădurilor (Lague et al., 2013; Shafaat et al., 2025), deoarece măsoară distanţele dintre doi nori de puncte de-a lungul normalelor locale ale suprafeţelor, reducând astfel efectul densităţii punctelor şi generând un prag statistic valid pentru detectarea modificărilor (Lague et al., 2013; Winiwarter et al., 2021). M3C2-EP (Multiscale Model-to-Model Cloud Comparison with Error Propagation) reprezintă o implementare avansată care ia în considerare propagarea erorilor în procesul de modelare, contribuind la reducerea rezultatelor fals pozitive în zonele cu suprafeţe complexe sau neregulate (Winiwarter et al., 2021).

1.2.4.2 Detectarea modificărilor fenologice versus creşterea reală

Erorile generate de mediu şi ciclurile biologice sezoniere pot masca creşterea reală a arborilor în norii de puncte LiDAR. Dezvoltarea frunzişului primăvara influenţează structura arborilor măsurată de instrumentele LiDAR, generând diferenţe vizibile în distribuţia punctelor din coronament (Simonson et al., 2018). Studiile bazate pe seturi de date hiper-temporale arată că aceste tehnologii pot detecta modificări ale fenologiei frunzelor la nivel centimetric, inclusiv diferenţe temporale între arbori ai aceleiaşi specii, de până la aproximativ 12 zile (Bienert et al., 2024; Campos et al., 2024). Condiţiile de mediu, precum precipitaţiile, modifică temporar poziţia ramurilor prin absorbţia apei şi schimbarea elasticităţii acestora, efect ce poate fi măsurat prin comparaţii bazate pe metoda M3C2 (Bienert et al., 2024). Ratele de creştere determinate cu ajutorul dispozitivelor mobile (obţinute prin scanări LiDAR repetate ale aceloraşi arbori în timp) au demonstrat capacitatea de a surprinde cu acurateţe traiectoriile de creştere, luând în considerare variabilitatea densităţii punctelor în experimente controlate (Qi et al., 2023). Prin utilizarea măsurătorilor terestre cu cost redus (date manuale DBH şi TH), modelele alometrice locale pot fi calibrate pentru a genera estimări ale biomasei cu rate ale erorii de până la 3%, comparativ cu estimările tradiţionale, care prezintă erori de aproximativ 15–30% (Qi et al., 2023).

1.2.4.3 Limitări cauzate de erori, înregistrare şi drift

Fiabilitatea analizelor multi-temporale este influenţată de mai multe constrângeri tehnice asociate sistemelor mobile de scanare. Alinierea precisă a norilor de puncte reprezintă un proces esenţial, care poate fi realizat prin utilizarea algoritmului ICP (Iterative Closest Point). Chiar şi nealinierea minoră pot influenţa interpretarea modificărilor structurale (Forkuo & Borz, 2023; Shafaat et al., 2025).

Nivelul tipic de detecţie (LoD95) pentru seturile de date corect înregistrate este cuprins între 2 şi 4 cm (Shafaat et al., 2025). Diferenţele mai mici decât acest prag sunt, de regulă, asociate incertitudinilor de

înregistrare, erorilor provenite de la senzor sau factorilor externi, precum vântul (Winiwarter et al., 2021; Shafaat et al., 2025). Metodele bazate pe SLAM prezintă tendința de acumulare a erorilor de poziționare, în special în cazul traiectoriilor lungi sau complexe. Acest fenomen poate conduce la reprezentări geometrice inexacte pentru fiecare suprafață de probă scanată (Liang et al., 2022; Balestra et al., 2024b). Pentru reducerea erorilor cumulative de poziționare, pot fi utilizate tehnici de tip loop closure, care asigură consistența geometrică între diferitele trasee de colectare sau perioade temporale (Liang et al., 2022). Vântul produce efecte de tip ghosting în norii de puncte, situație în care același element apare în mai multe poziții. Acest fenomen îngreunează detectarea modificărilor la nivelul coronamentului arborilor (Simonson et al., 2018).

1.2.5 Factori care influențează calitatea norilor de puncte

Această subsecțiune analizează factorii tehnici, biologici și operaționali care influențează calitatea și fiabilitatea reconstrucțiilor LiDAR 3D, identificând pragurile critice necesare pentru performanța eficientă a sistemelor cu cost redus. Interacțiunea dintre fasciculul laser și suprafața trunchiului este influențată de proprietățile morfologice ale speciilor (Mîzgaciu et al., 2025). Scoarța rugoasă a fost identificată ca una dintre principalele cauze ale erorilor sistematice; de exemplu, speciile cu textură pronunțată a scoarței, precum *Pinus sylvestris* sau *Quercus petraea*, prezintă o bandă reziduală mai largă în norul de puncte, ceea ce conduce frecvent la supraestimarea DBH în algoritmi de ajustare circulară (Bauwens et al., 2016; Holvoet et al., 2025; Výboštok et al., 2025). În schimb, speciile cu scoarță netedă, precum *Abies alba* sau *Fagus sylvatica*, generează provocări specifice pentru dispozitivele destinate consumatorilor (Výboštok et al., 2025). De exemplu, în cazul senzorilor Time-of-Flight (ToF) integrați în camerele smartphone-urilor, regiunile cu textură redusă a suprafeței diminuează stabilitatea alinierii cadrelor de profunzime, determinând software-ul să utilizeze interpolări interne care amplifică erorile metrice (Výboštok et al., 2025). În plus, excentricitatea trunchiului la speciile foioase produce erori atunci când se presupune o circularitate perfectă, sugerând că ajustarea eliptică reprezintă o soluție mai flexibilă și mai realistă (Wu et al., 2025a; Bauwens et al., 2016).

Calitatea rezultatelor cartării bazate pe SLAM depinde în mare măsură de comportamentul utilizatorului și de geometria traseelor parcurse (Chen et al., 2019; Sae-Ngow et al., 2025). Traseele închise (closed-loop paths) sunt esențiale pentru reducerea fenomenului de drift, deoarece permit sistemului să recunoască locații familiare și să corecteze erorile acumulate în procesul de odometrie (Gollob et al., 2020b; Vandendaele et al., 2022). Modul de deplasare al operatorului influențează unghiurile de scanare și uniformitatea acoperirii scenei (Chen et al., 2019; Gollob et al., 2021a). Asigurarea mai multor unghiuri de scanare în jurul fiecărui arbore, inclusiv prin trasee circulare sau randomizate, îmbunătățește completitudinea datelor comparativ cu utilizarea unei singure traiectorii rectilinii. Există, de asemenea, limitări generate de artefactele de mișcare, precum alinierea incorectă a scanărilor și efectele de ghosting produse de viteze mari de deplasare sau de repetarea aceleiași scanări de mai multe ori (Gollob et al., 2021b). În cele din urmă, competența operatorului reprezintă un factor critic pentru succesul general al planului de măsurare, în principal datorită capacității utilizatorilor experimentați de a implementa soluții eficiente de scanare în peisaje dense sau puternic ocluzionate (Chen et al., 2019; Sae-Ngow et al., 2025). Acuratețea variabilelor dendrometrice depinde de atingerea unor praguri minime de densitate a punctelor. Dacă densitatea punctelor scade sub aceste praguri, valoarea RMSE crește semnificativ, compromițând precizia măsurărilor. Pentru evaluarea DBH sunt necesare densități cuprinse între 600 și 700 puncte/m³ pentru menținerea erorii sub 1 cm (Khan et al., 2025; Výboštok et al., 2025). Densitățile mai mici de 200 puncte/m³ conduc la profile incomplete ale trunchiului, ceea ce poate invalida ajustarea automată (Khan et al., 2025). În cazul înălțimii arborilor, cerințele sunt mai puțin restrictive, precizia atingând un platou (RMSE < 1 m) începând de la aproximativ 300 puncte/m³, cu condiția ca senzorul să capteze corect vârful real al arborelui (Khan et al., 2025; Výboštok et al., 2025).

1.3 CONCLUZII

Digitalizarea aplicaţiilor de inventariere forestieră traversează o schimbare de paradigmă, determinată de tranziţia de la sistemele statice de colectare a datelor către sisteme mobile şi dispozitive destinate consumatorilor. Această tranziţie poate fi considerată o democratizare a acurateţii inventarierii forestiere, deoarece a permis dispozitivelor comerciale şi aplicaţiilor mobile să atingă un nivel ridicat de fiabilitate tehnică în utilizare. Cel mai important avantaj competitiv al acestor tehnologii constă în eficienţa colectării datelor la nivelul întregilor suprafeţe de probă în timpul deplasării, reducând semnificativ timpul necesar activităţilor de teren. În plus, integrarea aplicaţiilor cu capacităţi de procesare instantanee facilitează luarea deciziilor direct în teren şi elimină barierele logistice asociate post-procesării extinse în birou. Cu toate acestea, implementarea pe scară largă se confruntă încă cu limitări tehnice şi de mediu persistente. Înălţimea arborilor rămâne principala provocare pentru senzorii tereştri, din cauza ocluziei coronamentului şi a razei limitate a dispozitivelor cu cost redus, ceea ce conduce la o tendinţă sistematică de subestimare a structurii verticale. În plus, calitatea datelor depinde în mod critic de starea fenologică a pădurii, perioada fără frunziş (sfârşitul toamnei – începutul iernii) reprezentând condiţia optimă pentru asigurarea vizibilităţii trunchiurilor şi reconstrucţia precisă a terenului. Pentru monitorizarea multi-temporală şi urmărirea creşterii arborilor, aceste instrumente prezintă un potenţial considerabil, cu condiţia utilizării unor algoritmi robusţi de comparaţie, capabili să distingă modificările biologice reale de erorile tehnice sau instrumentale. În cele din urmă, viitorul silviculturii de precizie nu constă într-un singur senzor, ci în adoptarea unor fluxuri de lucru hibride, care integrează detaliile la nivelul trunchiului obţinute prin LiDAR mobil cu informaţiile asupra coronamentului furnizate de sistemele aeropurtate sau drone. Tehnologiile LiDAR cu cost redus au evoluat de la instrumente experimentale la componente esenţiale ale unei infrastructuri digitale de monitorizare forestieră, scalabilă şi accesibilă — infrastructură necesară pentru asigurarea sustenabilităţii resurselor forestiere globale.

CAPITOLUL 2. ACURATEȚEA APLICAȚIEI TREE SCANNER ÎN ESTIMAREA PARAMETRILOR BIOMETRICI AI ARBORILOR: STUDIU DE CAZ BAZAT PE DATE DIN DIFERITE ECOSISTEME FORESTIERE

2.1 MATERIALE ȘI METODE

Studiul a fost realizat în anul 2025 în cadrul a trei suprafețe forestiere din România, reprezentative pentru diferite compoziții forestiere și condiții topografice. Suprafețele din Buzău (BUZ) și Harghita (HAR) au fost localizate în Carpații Românești și au fost alcătuite în principal din păduri montane mixte de rășinoase și foioase, în timp ce suprafața din Botoșani (BOT) a reprezentat un ecosistem forestier colinar dominat de foioase. Arboretele au inclus specii precum fagul (*Fagus sylvatica* L.), molidul (*Picea abies* (L.) H. Karst), bradul (*Abies alba* Mill.), gorunul (*Quercus petraea* (Matt.) Liebl), carpenul (*Carpinus betulus* L.), jugastrul (*Acer campestre* L.) și cireșul sălbatic (*Prunus avium* L.).

Măsurătorile de referință pentru diametrul la înălțimea pieptului (DBH) și înălțimea arborilor (TH) au fost realizate utilizând instrumente forestiere convenționale. DBH-ul a fost măsurat la 1,3 m deasupra solului cu ajutorul unei clupe Haglöff Mantax Blue, cu precizie milimetrică, iar înălțimea arborilor a fost determinată utilizând un hipsometru ultrasonic Haglöff împreună cu un transponder T3. Măsurătorile digitale au fost realizate cu aplicația mobilă TreeScanner (TS) – versiune beta – dezvoltată în cadrul proiectului SINTETIC, rulată pe un dispozitiv iPhone 13 Pro Max echipat cu senzor LiDAR de tip Time-of-Flight (ToF). Aplicația integrează nori de puncte LiDAR, date GNSS, imagini și algoritmul RANSAC pentru estimarea variabilelor dendrometrice. Măsurătorile realizate prin ambele metode au fost efectuate în timpul zilei, în condiții de achiziție cât mai similare posibil. Colectarea datelor de teren a urmat un flux de lucru structurat, implicând trei roluri operaționale: o persoană responsabilă de efectuarea măsurătorilor, o echipă de suport responsabilă de logistică și identificarea arborilor și o persoană responsabilă de înregistrarea măsurătorilor convenționale. Comunicarea verbală a fost menținută pe tot parcursul procesului pentru a asigura sincronizarea și acuratețea datelor. Atât pentru DBH, cât și pentru TH, măsurătorile au fost efectuate din distanțe, direcții și câmpuri vizuale comparabile, iar orice abatere de la aceste condiții a fost consemnată în notele de teren.

Înainte de analiză, setul de date a fost supus unui proces de selecție pentru păstrarea exclusivă a măsurătorilor pereche colectate în condiții consistente de achiziție. Din totalul de 287 observații pereche inițiale pentru DBH și TH, au fost păstrate 220 de măsurători pentru analiza statistică. Analiza statistică a urmat un cadru standard de comparare a metodelor. Au fost calculate statistici descriptive și indicatori de acuratețe, inclusiv RMSE, MAE și bias (Heckman et al., 1998; Ross et al., 2013; Chai & Draxler, 2014; Hodson, 2022; Karunasingha, 2022). Normalitatea datelor a fost evaluată utilizând testele Shapiro-Wilk și D'Agostino-Pearson (Breton et al., 2008; D'Agostino et al., 1986; Shapiro & Wilk, 1965; Yap & Sim, 2011). Concordanța dintre măsurătorile TreeScanner și măsurătorile de referință a fost evaluată prin analiza Bland-Altman (Bland & Altman, 1999), iar modelele de regresie ordinary least squares (OLS) au fost utilizate pentru evaluarea relațiilor dintre seturile de date (Watson, 1967; Yuan et al., 2018; Van De Geer, 2008). De asemenea, au fost efectuate teste suplimentare de heteroscedasticitate, inclusiv testele Breusch-Pagan și White, pentru investigarea prezenței biasului proporțional. Gestionarea și vizualizarea datelor au fost realizate utilizând Microsoft Excel, QGIS și Microsoft PowerPoint. Analizele statistice au fost implementate în Python v. 3.12 utilizând biblioteci precum numpy, pandas, seaborn, matplotlib, statsmodels, pathlib și scipy, ceea ce a permis dezvoltarea unui flux complet pentru importul, analiza, vizualizarea și exportul rezultatelor.




Figura 2.1. Localizarea suprafețelor de studiu și prezentarea generală a metodologiei utilizate.

2.2 REZULTATE

2.2.1 Descrierea datelor

Din totalul de 287 de observații incluse în setul de date inițial, au fost păstrate 220 de măsurători viabile pe baza criteriilor utilizate pentru selectarea datelor. Dintre acestea, 90 (74%) au provenit din setul de date BOT, 10 (32%) din setul de date BUZ și 120 (89%) din setul de date HAR, reprezentând împreună aproximativ 77% din setul de date original. Tabelul 2.1 prezintă datele privind măsurătorile manuale și digitale ale DBH și TH, indicând faptul că cele două metode au produs valori similare ale mediei și abaterii standard, precum și distribuții similare ale datelor. Cu excepția reziduurilor pentru înălțime, niciunul dintre seturile de date nu îndeplinește ipoteza de normalitate. Pentru DBH, distribuțiile ambelor metode de măsurare au prezentat o asimetrie pozitivă, indicând o concentrare ridicată a arborilor în intervalul 15–35 cm, datorită caracteristicilor setului de date, care a conținut semnificativ mai multe date provenite din HAR. Cu toate acestea, a existat o concordanță excelentă între cele două metode în ceea ce privește distribuția datelor.

Tabelul 2.1. Statistici descriptive sintetice ale datelor.

Variabilă	N	Valoare minimă	Valoare maximă	Media ± abaterea standard	Cuartila 1	Mediană	Cuartila 3
d_clupă (cm)	220	10.70	87.90	28.61±14.285	20.35	24.95	31.53
d_treescanner (cm)	220	10.40	87.83	28.54±14.533	20.39	24.65	31.40
h_vertex (m)	220	4.00	44.40	22.80±6.182	19.00	22.60	25.73
h_treescanner (m)	220	3.77	42.87	22.54±6.367	18.54	22.38	25.42

Pentru înălțimea arborilor, distribuțiile au fost mai simetrice și au aproximat distribuții normale, centrate în jurul unei valori medii situate în intervalul 23–25 m. Curbele de densitate REF și TS s-au suprapus aproape perfect, indicând o acuratețe constantă a măsurătorilor în raport cu variabilitatea înălțimii arborilor. Reziduurile, definite ca diferențele dintre valorile estimate și cele reale, ar trebui în mod ideal să fie distribuite normal și centrate în jurul valorii zero pentru modelarea prin regresie (Schmidt & Finan 2018, Montgomery et al. 2021). Reziduurile DBH au avut o valoare medie foarte apropiată de zero, indicând absența unor supraestimări sau subestimări sistematice majore, majoritatea erorilor încadrându-se în intervalul $\pm 1,5$ cm și foarte puține valori extreme depășind ± 3 cm. În schimb, reziduurile TH au fost

centrate în jurul valorii zero, distribuite în intervalul $\pm 1,0$ m şi au prezentat o curbă clară în formă de clopot, sugerând că erorile de măsurare a înălţimii sunt aleatorii şi nu sunt influenţate de erori sistematice ale TS. Setul de date al reziduurilor pentru înălţime a fost singurul confirmat ca urmând o distribuţie normală conform testelor statistice implementate.

2.2.2 Concordanţa măsurătorilor

Concordanţa dintre datele TS (test) şi REF (referinţă) este ilustrată în Figurile 2.2–2.4. Aceste figuri includ rezultatele diagramelor Bland–Altman (Figura 2.2), graficele măsurătorilor privind diametrul şi înălţimea ajustate cu modele de regresie liniară prin metoda celor mai mici pătrate (Figura 2.3) şi tendinţele erorilor (Figura 2.4). Rezultatele prezentate în Figurile 2.2–2.4 susţin datele prezentate în Tabelul 3, indicând un grad ridicat de concordanţă. Pentru măsurarea DBH (Figura 2.2a), eroarea sistematică a fost foarte mică, de $-0,07$ cm ($-0,3\%$). Majoritatea observaţiilor s-au încadrat în limitele de concordanţă de 95%, aproximativ între ± 2 cm. În consecinţă, erorile au rămas stabile pe întregul interval al diametrelor (de la aproximativ 10 până la aproape 90 cm), existând doar câteva valori extreme la diametre mai mari. Luând în considerare indicatorii MAE (Mean Absolute Error) şi RMSE (Root Mean Square Error), măsurătoarea medie a diametrului obţinută prin TS diferă de referinţa manuală cu mai puţin de 1 cm (MAE = $0,75$ cm). Indicatorul RMSE, care este neliniar şi serveşte drept măsură a preciziei — acordând o pondere mai mare valorilor mari ale erorii — indică o variabilitate redusă a erorilor comparativ cu MAE. În concordanţă cu celelalte rezultate pentru DBH, RMSE a fost de asemenea mai mic de 1 cm, evidenţiind un nivel ridicat de concordanţă între datele DBH TS şi REF. Rezultate similare, cu un grad ridicat de acurateţe, au fost obţinute şi pentru înălţimea arborilor măsurată prin TS. A existat o uşoară subestimare sistematică de $-0,26$ m ($-1,1\%$) realizată de TS, cu limite de concordanţă mai restrânse (aproximativ între $-1,7$ şi $1,2$ m). MAE a fost mai mic de 1 m ($0,65$), iar RMSE a fost din nou sub 1 m ($0,79$ m), indicând consistenţă în măsurători şi o variabilitate redusă a erorilor.




Figura 2.2. Diagrame Bland–Altman privind concordanţa măsurătorilor de diametru şi înălţime.

Graficele prezentate în Figura 2.3 demonstrează o corelaţie excepţională între metodele digitale (TS) şi cele manuale (REF). De exemplu, măsurătorile DBH au evidenţiat o relaţie aproape perfect liniară (termen liber = $0,51$ cm, coeficientul de regresie = $1,02$), surprinzând într-o foarte mare măsură variaţia măsurătorilor manuale ($99,6\%$, $R^2 = 0,996$). Deşi uşor mai redusă comparativ cu măsurătorile de diametru, metoda de măsurare TS a demonstrat o acurateţe ridicată pentru înălţime (termen liber = $0,79$ m, coeficient de regresie = $1,02$), captând de asemenea eficient variaţia măsurătorilor manuale ($98,7\%$, $R^2 = 0,987$). Datele provenite din zonele analizate (BOT, BUZ, HAR) s-au grupat strâns de-a lungul liniei de

egalitate (linia 1:1), sugerând o performanță consistentă în diferite medii forestiere, pentru diverse specii și dimensiuni ale arborilor.




Figura 2.3. Grafice ale diametrului și înălțimii ajustate cu modele de regresie liniară prin metoda celor mai mici pătrate.

Tendențele erorilor sunt ilustrate în Figura 2.4, care analizează dacă erorile sunt aleatorii sau influențate de magnitudinea DBH și TH. Pentru DBH, aproape că nu a existat dependență între eroare și magnitudinea DBH ($R^2 = 0,05$); totuși, testele statistice utilizate au indicat prezența heteroscedasticității. Per ansamblu, datele din Figura 2.4a sugerează existența unei heteroscedasticități cu efect redus, variind de la o subestimare nesemnificativă în intervalele inferioare ale diametrului până la o foarte ușoară supraestimare în intervalele superioare ale diametrului. Punctele de date au rămas relativ uniform distribuite, cu un profil plat al reziduurilor. Pentru TH, o tendință foarte ușor ascendentă ($R^2 = 0,04$) sugerează o tranziție minoră de la subestimare la supraestimare în cazul arborilor mai înalți, deși varianța rămâne stabilă, așa cum se observă în Figura 2.4b. Testele statistice au indicat de asemenea prezența heteroscedasticității.




Figura 2.4. Tendențele erorilor de măsurare pentru DBH și TH.

2.3 CONCLUZII

Scopul studiului a fost evaluarea acurateţii aplicaţiei mobile TS în estimarea diametrului la înălţimea pieptului (DBH) şi a înălţimii totale a arborilor (TH) în ecosisteme forestiere diverse. Rezultatele evidenţiază un nivel ridicat de concordanţă între estimările obţinute cu aplicaţia TS şi estimările de referinţă (REF) pentru cele trei ecosisteme forestiere analizate în cadrul studiului. Acurateţea rezultatelor măsurării DBH obţinute cu TS a indicat o fidelitate ridicată, subcentimetrică, fără biasuri şi erori semnificative. În mod similar, rezultatele obţinute pentru măsurarea TH au indicat o acurateţe ridicată, submetrică, în raport cu datele de referinţă, rezultatele fiind uşor subestimate. Analiza de regresie a confirmat existenţa unei relaţii liniare foarte puternice între măsurătorile digitale şi cele manuale, validând astfel capacitatea aplicaţiei de a reprezenta variabilitatea observată în măsurătorile convenţionale. Analiza concordanţei şi evaluarea tendinţelor erorilor au indicat că diferenţele dintre măsurători au fost stabile pentru toate clasele dimensionale ale arborilor, cu o heteroscedasticitate redusă. Aceste rezultate sugerează că Tree Scanner poate furniza măsurători fiabile şi precise într-o varietate de structuri forestiere, compoziţii de specii şi condiţii de teren. Portabilitatea smartphone-urilor şi posibilitatea înregistrării directe a măsurătorilor digitale evidenţiază potenţialul acestei tehnologii de a susţine fluxuri de lucru mai eficiente în inventarierea forestieră şi de a elimina transcrierea manuală a datelor. În ciuda rezultatelor încurajatoare obţinute în acest studiu, este important de menţionat că acesta a acoperit doar câteva locaţii şi condiţii forestiere specifice. Prin urmare, se recomandă realizarea unor cercetări suplimentare pentru evaluarea eficienţei tehnologiilor LiDAR bazate pe smartphone într-o gamă mai largă de structuri forestiere, inclusiv în păduri cu subarboret mai dens. De asemenea, se recomandă ca dezvoltările viitoare ale acestei tehnologii să se concentreze pe integrarea altor parametri forestieri, precum identificarea speciilor.

CAPITOLUL 3. ACURATEŢEA ŞI EFICIENŢA TEMPORALĂ A UNEI NOI APLICAŢII DEZVOLTATE PENTRU ACHIZIŢIA ŞI CARTAREA DATELOR INDIVIDUALE ALE ARBORILOR: O COMPARAŢIE CU COLECTOARELE LIDAR DE ULTIMĂ GENERAŢIE ÎN CEEA CE PRIVEŞTE ESTIMAREA SUPRAFEŢEI DE BAZĂ

3.1 MATERIALE ŞI METODE

Studiul a comparat două platforme de inventariere forestieră bazate pe tehnologia LiDAR mobilă: aplicația mobilă Tree Scanner (Platforma 1) și scannerul laser personal FJD Trion P1 (Platforma 2). Tree Scanner, dezvoltată în cadrul proiectului SINTETIC, utilizează senzori LiDAR, GNSS, imagini captate cu camera, algoritmi bazați pe inteligență artificială și algoritmul RANSAC pentru estimarea variabilelor dendrometrice, precum DBH și înălțimea arborilor, din nori de puncte 3D de înaltă rezoluție (Poveda & Ekenstedt, 2024). Aplicația a fost utilizată pe un iPhone 13 Pro Max echipat cu un senzor LiDAR de tip Time-of-Flight (ToF). FJD Trion P1 este un scanner laser personal compact, capabil să genereze nori de puncte 3D denși utilizând tehnologia SLAM, cu o rază de scanare de până la 40 m și o precizie de aproximativ 2 cm (FJDynamic, 2025). Norii de puncte colectați cu Platforma 2 au fost procesați utilizând software-ul Trion Model pentru identificarea arborilor și estimarea automată a DBH prin ajustare geometrică la 1,3 m deasupra nivelului solului. Studiul a fost realizat în pădurile din apropierea municipiului Braşov, România, selectate pentru a reprezenta o gamă largă de condiții forestiere care pot influența măsurătorile LiDAR, inclusiv variații ale densității arboretului, acoperirii coronamentului, pantei terenului, subarboretului și vârstei arborilor (Wallace et al., 2014; Balsi et al., 2018; Sandim et al., 2023). În aria de studiu au fost amplasate cincizeci de suprafețe circulare de probă de 300 m². În analiză au fost incluși arborii cu DBH mai mare de 10 cm și cu cel puțin 50% din tulpină situată în interiorul limitei suprafeței de probă. Centrele suprafețelor au fost georeferențiate utilizând un dispozitiv GPS portabil (GPSMAP 64sx, Garmin).




Figura 3.1. Aria de studiu care prezintă: a – localizarea ariei de studiu la nivel național, b – localizarea unităților amenajistice selectate și c – localizarea suprafețelor de probă.

Colectarea datelor a fost realizată în perioada de repaus vegetativ, între 12 și 20 decembrie 2024. În fiecare suprafață de probă, toți arborii au fost măsurați individual utilizând Platforma 1, iar valorile DBH au fost înregistrate manual. Ulterior, aceleași suprafețe au fost scanate utilizând Platforma 2, urmând un model standardizat de scanare constând în patru traiectorii eliptice. Vizualizarea în timp real a norului de puncte a fost utilizată în teren pentru a asigura acoperirea adecvată a tuturor arborilor.

Comparația dintre platforme s-a concentrat asupra estimărilor DBH, estimărilor suprafeței de bază (BA) și consumului de timp. Deoarece arborii nu au fost marcați individual și asocierea directă a măsurătorilor la nivel de arbore între platforme nu a fost posibilă, seturile de date DBH au fost ordonate incremental după magnitudine pentru comparație. Suprafața de bază la hectar la nivel de suprafață de probă a fost calculată separat pentru fiecare platformă utilizând estimările DBH corespunzătoare. Datele Platformei 2 au fost considerate referința operațională datorită preciziei ridicate și informațiilor tridimensionale detaliate furnizate.

Analiza statistică a inclus statistici descriptive, evaluarea normalității utilizând testul D'Agostino-Pearson și analiza regresiei pentru evaluarea relațiilor dintre seturile de date. Concordanța dintre estimările suprafeței de bază a fost evaluată utilizând eroarea sistematică, eroarea medie absolută (MAE) și rădăcina pătrată a erorii medii pătratice (RMSE) (Holst & Thyregod, 1999; Willmott & Matsuura, 2005; Willmott et al., 2009; Hodson, 2022). În funcție de distribuția datelor, au fost aplicate fie teste t independente bilaterale, fie teste Mann-Whitney pentru compararea seturilor de date (Pereira & Leslie, 2010). Heteroscedasticitatea a fost evaluată utilizând testele Breusch-Pagan și White pentru a analiza potențialele erori proporționale al reziduurilor (Breusch & Pagan, 1979; White, 1980). De asemenea, a fost utilizată regresia prin origine pentru evaluarea proporției variației explicate între platforme.


Eficiența operațională a fost evaluată prin înregistrarea timpilor de achiziție pentru ambele sisteme. Pentru Platforma 1, timpul per arbore a inclus configurarea aplicației, măsurarea și stocarea datelor, în timp ce pentru Platforma 2 timpul total de scanare a inclus configurarea scannerului, scanarea suprafeței de probă și salvarea datelor. Consumul de timp a fost analizat suplimentar în raport cu caracteristicile arboretului, precum vârsta, densitatea, panta și numărul de arbori per suprafață de probă.

Toate analizele statistice au fost efectuate în Microsoft Excel utilizând extensia Real Statistics (Real Statistics Using Excel, 2025). Procesarea datelor LiDAR a fost realizată pe o stație de lucru de înaltă performanță echipată cu procesor Intel Core i9, 64 GB RAM, placă video NVIDIA GeForce RTX 4070 și sistem de operare Windows 11 Pro.


3.2 REZULTATE

3.2.1 Măsurători la nivel de arbore


Statisticile principale ale măsurătorilor la nivel de arbore ($N = 618$) sunt ilustrate în Figura 3.2. Ipoteza de normalitate pentru DA (datele de diametru provenite de la Platforma 1), TDA (datele de timp de procesare la nivel de arbore pentru Platforma 1) și DS (datele de diametru provenite de la Platforma 2) nu a fost îndeplinită conform testului D'Agostino-Pearson ($\alpha = 0,05$, $p > 0,05$). Cu toate acestea, distribuțiile datelor DA și DS au fost similare (diagramele tip boxplot sunt prezentate în Fig. 3.2a), cu un interval pentru DA de 9,0 până la 88,9 cm (media $\pm$ SD: $34,3 \pm 15,83$ cm) și un interval pentru DS de 10,0 până la 87,8 cm (media $\pm$ SD: $35,1 \pm 15,88$ cm). În plus, cele două distribuții de date ordonate incremental în funcție de mărimea DBH măsurat au arătat un grad ridicat de concordanță între cele două tipuri de măsurători (Figura 3.2d).




a



b



c



d

Figura 3.2. Statistici descriptive de bază ale măsurătorilor la nivel de arbore: a – statistici descriptive pentru DA și DS, b – statistici descriptive pentru TDA, c – dependența TDA în funcție de DA, d – diferența dintre DA și DS pe baza datelor ordonate incremental.

3.2.2 Concordanța și diferențele estimărilor suprafeței de bază

Rezultatele indică că a existat o concordanță puternică și o similitudine a estimărilor suprafeței de bază, așa cum este prezentat în Tabelele 3.1, 3.2 și Figura 3.3. Intervalele intercuartile ale estimărilor la nivel de hectar pentru suprafața de bază obținute cu cele două platforme au fost similare (20,130 vs. 19,334 m²). După cum este prezentat în Tabelul 3.1, distribuțiile acestor variabile au fost similare și normale ($\alpha = 0,05$, $p > 0,05$), fără diferențe statistice semnificative ($\alpha = 0,05$, $p > 0,05$) între mediile acestora ($46,082 \pm 13,909$ vs. $48,033 \pm 14,660$). În plus, a existat un grad ridicat de concordanță în estimări, așa cum este evidențiat în Tabelul 3.2 și Figura 3.3.

Tabelul 3.1. Statistici descriptive ale suprafeței de bază la nivel de suprafață de probă și pe hectar.

Parametru	Statistici descriptive						
	Valoarea minimă	Valoarea maximă	Amplitudinea de variație	Valoarea medie	Abaterea standard	Distribuția datelor ¹	Compararea datelor ²
Suprafață de bază pe hectar provenită de la Platforma 1, BAAH (m ² /ha)	15.951	72.526	56.575	46.082	±13.909	Normală I, $p = 0.129$	Fără diferențe. $p = 0.497$
Suprafață de bază pe hectar provenită de la Platforma 2, BASH (m ² /ha)	16.262	77.886	61.625	48.033	±14.660	Normală, $p = 0.305$	

Notă: ¹ – conform testului D'Agostino-Pearson ($\alpha = 0,05$, $p > 0,05$), ² – conform testului t independent bilateral ($\alpha = 0.05$, $p > 0.05$).

Tabelul 3.2. Diferențe în estimările suprafeței de bază

Parametru	Metrică a diferențelor, distribuția datelor și prezența heteroscedasticității				
	BIAS	MAE	RMSE	Distribuția datelor ¹	Heteroscedasticitate ²
Suprafață de bază pe hectar provenită de la Platforma 1, BAAH (m ² /ha)	1.950	2.292	3.085	Normală, $p = 0.129$	Fără heteroscedasticitate
Suprafață de bază pe hectar provenită de la Platforma 2, BASH (m ² /ha)				Normală, $p = 0.305$	pBP = 0.320, pW = 0.608

Notă: ¹ – conform testului D'Agostino-Pearson ($\alpha = 0,05$, $p > 0,05$), ² – conform testelor Breusch-Pagan și White ($\alpha = 0,05$, $p > 0,05$), unde pBP și pW reprezintă valorile p bilaterale ale testelor Breusch-Pagan și, respectiv, White.




Figura 3.3. Concordanța estimărilor suprafeței de bază.

Cu o valoare BIAS de 1,950 m²/ha (Tabelul 3.2), indicând o ușoară tendință de creștere în funcție de magnitudinea suprafeței de bază, rezultatele privind acuratețea estimărilor sunt promițătoare. În plus, nu a fost identificată nicio dovadă statistică de heteroscedasticitate liniară sau de alt tip (Tabelul 3.2), ceea ce sugerează stabilitatea varianței atât în ceea ce privește datele utilizate pentru estimarea suprafeței de bază, cât și estimările rezultate. Prin urmare, acest studiu a identificat, în medie, diferențe minore în estimări (aproximativ 2 m²/ha), cu o tendință ca Platforma 1 să subestimeze în raport cu datele furnizate de Platforma 2. Indicatorul RMSE, care penalizează diferențele mari, a indicat de asemenea diferențe reduse, de aproximativ 3 m²/ha. Figura 3.3 oferă detalii privind compararea datelor și gradul de concordanță, luând în considerare estimările suprafeței de bază modelate prin regresie. Tendința liniară arată un coeficient de determinare ridicat în explicarea BAAH ca funcție liniară de BASH. Practic, aproape toată variația BAAH a fost explicată de BASH. Diferențele dintre estimările suprafeței de bază au fost în mod constant mai mici de 3,1 m²/ha, indiferent de indicatorul de diferență considerat. Totuși, în funcție de situație, diferențele semnate pot varia între -4 (supraestimare) și 9 m²/ha (subestimare).

3.2.3 Consumul de timp

Consumul de timp la nivel de arbore pentru Platforma 1 (TDA) a prezentat, în general, o gamă largă de valori (Figura 3.2a); cu toate acestea, nu a fost identificată nicio dependență evidentă față de DA (Figura 3.2b), iar consumul mediu de timp la nivel de arbore pentru măsurarea cu Platforma 1 a fost de 11 secunde.

Utilizând Platforma 2, obținerea rezultatelor pentru DBH și suprafața de bază necesită mai mulți pași suplimentari de procesare. Acești pași includ descărcarea sau transferul datelor de pe instrument pe un PC și apoi curățarea norului de puncte. Pentru această etapă a fost utilizat software-ul Trion Model de la FJDynamics. Procesul a constat în principal în eliminarea automată a punctelor care nu corespundeau vegetației reale sau terenului, cu scopul de a îmbunătăți calitatea norului de puncte. Ulterior, același software a fost utilizat pentru extragerea terenului și segmentarea automată a arborilor în grupuri. Acest software utilizează algoritmi pentru ajustarea automată a cercurilor sau elipselor la secțiunea transversală a arborilor la o înălțime de 1,3 metri. În acest mod, DBH poate fi obținut din datele LiDAR fără intervenție manuală. Uneori a fost necesară segmentarea manuală sau editarea în software pentru a identifica mai bine arborii cu structură complexă sau pentru a corecta mici erori în norul de puncte. Toți acești pași au fost necesari pentru a produce estimările DBH la nivel de arbore utilizând Platforma 2 și au fost efectuați pe arhitectura de calcul descrisă în Secțiunea 2.3. Totuși, comparațiile privind consumul de timp au fost realizate doar pe datele TDA și TDS, care reflectă timpul necesar pentru efectuarea măsurătorilor în teren. Tendințele liniare dintre TDA sau TDS și variabilele independente, precum numărul de arbori măsurați, vârsta, densitatea și panta caracterizând compartimentele forestiere analizate, au fost slabe, așa cum se

observă, de exemplu, în Figura 3.4a. Prin urmare, încercarea de a dezvolta modele de predicție a consumului efectiv de timp pentru platformele utilizate nu a avut succes, deoarece ipoteza de linearitate nu a fost îndeplinită. Cu toate acestea, cu Platforma 1, timpul necesar la nivel de suprafață de probă pentru măsurarea DBH a arborilor a fost semnificativ mai redus, așa cum este demonstrat în Figura 3.4b și Tabelul 3, fiind în medie de aproximativ cinci ori mai mic comparativ cu Platforma 2. La nivel de arbore, acest lucru a rezultat în aproximativ 11 secunde necesare pentru măsurarea unui arbore cu Platforma 1, comparativ cu aproximativ 51 de secunde pentru Platforma 2.




Figura 3.4. Statistici ale consumului de timp la nivel de suprafață de probă: a – diagramă de dispersie a măsurătorilor TDA și TDS în funcție de numărul de arbori, b – boxplot-uri pentru datele TDA și TDS.

Tabelul 3.3. Statistici descriptive ale consumului de timp la nivel de suprafață de probă și arbore.

Parametru	Statistici descriptive						
	Valoare minimă	Valoare maximă	Amplitudinea de variație	Valoarea medie	Abaterea standard	Distribuția datelor ¹	Compararea datelor ²
TDA (s/ suprafață de probă)	24	498	474	135.3	±100.83	Non-normală $p < 0.001$	Diferențe semnificative
TDS (s/ suprafață de probă)	456	782	326	628.1	±87.32	Non-normală $p < 0.001$	$p < 0.001$
TDA (s/arbore)	-	-	-	11	-	-	-
TDS (s/arbore)	-	-	-	51	-	-	-

Notă: ¹ – conform testului D’Agostino-Pearson ($\alpha = 0,05$), ² – conform testului neparametric Mann-Whitney ($\alpha = 0,05$)

Totuși, trebuie luate în considerare diferențele importante atunci când se evaluează o abordare integrală a problemei. Nu s-a realizat sincronizarea datelor pentru Platforma 1, deoarece această platformă era un prototip, astfel că nu a putut fi obținută o imagine completă. În schimb, a fost realizat un experiment integral pentru Platforma 2, permițând generarea unor valori care caracterizează consumul de timp la nivel de arbore. Mai exact, pentru Platforma 1, consumul de timp per suprafață de probă și per arbore a fost de aproximativ 0,038 ore = 2 min și 17 sec, respectiv 0,003 ore = 11 secunde. Pentru Platforma 2, doar scanarea a durat aproximativ 0,174 ore = 10 min și 26 sec per suprafață de probă și 0,014 ore = 51 secunde per arbore. Atunci când se ia în considerare întregul efort necesar pentru obținerea datelor DBH cu Platforma 2, consumul de timp per suprafață de probă și per arbore a crescut la 1,969 ore = 118 min și 8 sec, respectiv 0,159 ore = 9 min și 32 sec.

3.3 CONCLUZII

Pe baza studiului, aplicația dezvoltată a demonstrat performanțe remarcabile în ceea ce privește acuratețea și eficiența temporală pentru măsurători atât la nivel de arbore, cât și la nivel de suprafață de probă. În plus, mobilitatea acesteia oferă o alternativă practică pentru colectarea datelor la nivel de arbore, la costuri semnificativ mai reduse. Totuși, sunt încă necesare îmbunătățiri, iar cercetări suplimentare sunt necesare pentru a înțelege pe deplin și a caracteriza capabilitățile aplicației. În ciuda unor provocări tehnice, rezultatele indică în mod clar un grad ridicat de eficiență al aplicației dezvoltate. Cercetările viitoare ar trebui să se concentreze pe testarea aplicației în diverse tipuri de păduri și medii operaționale, caracterizate de o diversitate mai mare de specii și dimensiuni ale arborilor, precum și de parametri de mediu variabili.

CAPITOLUL 4. PERFORMANȚA SEZONIERĂ ÎN ESTIMAREA SUPRAFEȚEI DE BAZĂ: UN STUDIU COMPARATIV ÎNTRE O APLICAȚIE LIDAR PE SMARTPHONE ȘI UN SCANNER LASER PERSONAL PROFESIONAL

4.1 MATERIALE ȘI METODE

Studiul a fost realizat în păduri montane temperate din apropierea municipiului Braşov, România, utilizând cincizeci de suprafețe circulare de probă de 300 m², distribuite de-a lungul unui gradient altitudinal de 580–1350 m d.m. Suprafețele au fost selectate pentru a reprezenta o gamă largă de structuri forestiere, compoziții și stadii de succesiune, incluzând arborete dominate de fag european (*Fagus sylvatica*), molid (*Picea abies*), brad (*Abies alba*), gorun (*Quercus petraea*), pin silvestru (*Pinus sylvestris*) și carpen (*Carpinus betulus*). Zona de studiu a inclus condiții de teren variabile, cu pante între 8° și 42°, vegetație de subarboret diversă și densități ale arborilor între 5 și 24 de arbori per suprafață de probă, generând condiții caracterizate de frecvente fenomene de ocluziune. Au fost incluși doar arborii cu DBH > 10 cm și cu mai mult de 50% din secțiunea transversală a tulpinii situată în interiorul razei suprafeței de probă, conform recomandărilor pentru detecția fiabilă a tulpinilor pe baza LiDAR (Liang et al., 2018a; Gollob et al., 2020; Tatsumi et al., 2022; Forkuo et al., 2025). Studiul a comparat două platforme de teledetecție proximală: aplicația smartphone TreeScanner și scannerul laser personal profesional FJD Trion P1. TreeScanner, dezvoltată în cadrul proiectului SINTETIC, funcționează pe dispozitive iOS echipate cu LiDAR și integrează tehnologie LiDAR VCSEL, poziționare GNSS și algoritmi AI-RANSAC pentru detecția tulpinilor și estimarea DBH (Luetzenburg et al., 2021; SINTETIC, 2023). FJD Trion P1 a fost utilizat ca referință profesională datorită densității ridicate a norului de puncte, capacității de scanare bazate pe SLAM și unei precizii relative nominale de aproximativ 2 cm (FJDynamics, 2026).

A fost implementat un design longitudinal cu măsurători repetate pe parcursul a patru sezoane fenologice: iarnă (WI, fără frunziș), primăvară (SP, început de înfrunzire), vară (SU, vegetație și subarboret dens) și toamnă (AU, pierdere parțială a frunzișului). Campaniile sezoniere au fost realizate între decembrie 2024 și octombrie 2025. Acest design a permis evaluarea modului în care condițiile sezoniere ale vegetației influențează calitatea norului de puncte, detecția tulpinilor, estimarea suprafeței de bază și eficiența operațională.

Pentru fiecare suprafață de probă, măsurătorile cu TreeScanner au fost realizate individual pentru toți arborii eligibili, în timp ce scanările cu FJD Trion P1 au fost efectuate utilizând patru traiectorii eliptice care depășeau raza parcelei, pentru a asigura o acoperire completă. Consumul de timp a fost înregistrat separat pentru ambele platforme. Pentru TreeScanner, timpul de achiziție a inclus inițializarea aplicației, scanarea tulpinilor, calculul DBH și salvarea fișierelor, dar a exclus deplasarea între arbori. Pentru FJD Trion P1, timpul total de scanare a inclus configurarea scannerului, deplasarea pe traiectoriile de scanare, închiderea buclei SLAM și salvarea datelor.

Datele norilor de puncte obținute cu FJD Trion P1 au fost procesate utilizând software-ul oficial Trion Model, care a realizat rafinarea, segmentarea și estimarea automată a DBH prin ajustarea formelor geometrice la secțiunile transversale ale tulpinilor la înălțimea pieptului. Măsurătorile la nivel de arbore au fost agregate pentru a estima suprafața de bază (BA) la nivel de parcelă. Analizele statistice au fost efectuate în Python 3.12 utilizând scripturi personalizate pentru agregare sezonieră, estimarea erorilor și testarea ipotezelor, în timp ce Microsoft Excel a fost utilizat pentru organizarea și verificarea datelor.

Analiza statistică a evaluat concordanța între platforme și eficiența operațională în funcție de sezon. Normalitatea datelor privind suprafața de bază și timpul a fost evaluată utilizând testele Shapiro-Wilk și Kolmogorov-Smirnov. Au fost calculate statistici descriptive pentru fiecare sezon, iar concordanța între platforme a fost analizată prin analiza Bland–Altman și regresie liniară. Indicatorii de eroare au inclus biasul (BIAS), eroarea medie absolută (MAE) și rădăcina pătrată a erorii medii pătratice (RMSE) (Willmott & Matsuura, 2005; Chai & Draxler, 2014). În funcție de distribuția datelor, au fost utilizate fie teste t pereche, fie teste Wilcoxon pentru eșantioane pereche pentru compararea estimărilor suprafeței de bază și a timpilor de achiziție între platforme (Wilcoxon, 1945; Pereira & Leslie, 2010; Mishra et al., 2019). Diagramele de dispersie și analizele de regresie au fost utilizate suplimentar pentru evaluarea concordanței sezoniere între TreeScanner și FJD Trion P1, unde pantele apropiate de 1 și valorile R² ridicate au fost interpretate ca indicând o concordanță mai puternică (Giavarina, 2015).

4.2 REZULTATE

4.2.1 Estimări sezoniere ale suprafeţei de bază la nivel de suprafaţă de probă şi consumul de timp pentru achiziţie

Ciclul complet anual de inventariere a fost finalizat cu succes în toate suprafeţele de probă. Un total de 618 arbori au fost înregistraţi în Iarnă (WI) şi Primăvară (SP), scăzând la 617 în Vară (SU) şi Toamnă (AU) din cauza căderii unui arbore în suprafaţa de probă 16. Tabelul 4.1 sintetizează caracteristicile biometrice la nivel de arboret şi timpii operaţionali pe sezoane.

Tabelul 4.1. Suprafaţa de bază la nivel de suprafaţă de probă şi timpul de achiziţie pe sezoane ($n=50$).

Sezon	NT (arbore/ suprafaţă de probă)	BAA (m ²)	BAS (m ²)	TA (s/ suprafaţă de probă)	TS (s/ suprafaţă de probă)
WI	12.36 ± 4.68	1.38 ± 0.41	1.44 ± 0.43	136.18 ± 99.46	628.12 ± 86.44
SP	12.36 ± 4.68	1.54 ± 0.43	1.73 ± 0.49	109.16 ± 50.48	653.96 ± 146.1
SU	12.34a ± 4.67	1.63 ± 0.44	1.79 ± 0.51	135.08 ± 60.48	604.44 ± 87.87
AU	12.34a ± 4.67	1.75 ± 0.55	1.68 ± 0.49	110.98 ± 39.86	498.66 ± 86.09

Notă: Valorile sunt medie ± abatere standard. BAA – suprafaţa de bază estimată cu TreeScanner; BAS – suprafaţa de bază estimată cu FJD Trion P1; TA – timp de achiziţie per suprafaţă de probă (TreeScanner); TS – timp de scanare per suprafaţă de probă (FJD Trion P1). ^a reducere datorată unui arbore căzut în suprafaţa de probă 16.

Estimările TreeScanner au arătat o bună concordanţă comparativ cu cele obţinute cu FJD Trion P1 în WI şi AU, cu o diferenţă medie de până la 0,06 m². Cele mai mari diferenţe au fost observate în SP, atingând 0,19 m². Atât FJD Trion P1, cât şi TreeScanner au prezentat tipare similare în tendinţa de creştere a suprafeţei de bază medii pe parcursul ciclului fenologic, în concordanţă cu tiparele de creştere sezonieră din pădurile temperate mixte. În ceea ce priveşte eficienţa operaţională, timpul mediu de scanare per suprafaţă de probă utilizând FJD Trion P1 (TS) a variat de la 498,66 ± 86,09 s în AU la 653,96 ± 146,1 s în SP. Aceste valori reflectă timpul necesar pentru configurarea echipamentului şi salvarea datelor, precum şi timpul necesar parcurgerii rutelor de scanare prestabilite. Pentru TreeScanner, timpul total de achiziţie per suprafaţă de probă (TA) a variat între 109,16 ± 50,48 s în SP şi 136,18 ± 99,46 s în WI. TA a fost măsurat la nivel de arbore individual şi nu include timpul de deplasare între arbori. Testele de normalitate au arătat că variabilele de suprafaţă de bază la nivel de suprafaţă de probă au fost distribuite normal în toate sezoanele (Shapiro-Wilk, $p > 0,05$), susţinând utilizarea testelor t pereche. În contrast, datele TA şi TS nu au avut distribuţie normală ($p < 0,05$), susţinând utilizarea testelor Wilcoxon pentru eşantioane pereche.

4.2.2 Concordanţa inter-platforme şi metrici de eroare

Concordanţa sezonieră între estimările TreeScanner (BAA) şi FJD Trion P1 (BAS) a variat în funcţie de stadiile fenologice, conform Tabelului 4.2 şi Figura 4.1.

Tabelul 4.2. Metrici de eroare sezoniere pentru suprafaţa de bază la nivel de parcelă (m²).

Sezon	Bias (m ²)	MAE (m ²)	RMSE (m ²)	(R ²)
Iarnă (WI)	-0.059	0.069	0.093	0.097
Primăvară (SP)	-0.184	0.299	0.391	0.031
Vară (SU)	-0.158	0.256	0.317	0.075
Toamnă (AU)	0.073	0.232	0.306	0.056

Notă: Bias, MAE, RMSE şi R² (reziduuri vs. medie) sunt raportate pe sezoane. Valorile scăzute ale R² indică o evidenţă limitată a biasului proporţional.

WI a prezentat cel mai ridicat nivel de concordanţă în ceea ce priveşte suprafaţa de bază, cu cel mai mic RMSE (0,093 m²) şi un bias aproape zero (-0,059 m²). Pe de altă parte, cel mai scăzut nivel de concordanţă a fost observat în SP, unde RMSE a crescut la 0,391 m². În plus, biasul de subestimare sistematică a crescut la -0,184 m². SU şi AU au prezentat performanţe intermediare în ceea ce priveşte concordanţa. Totuşi, AU

a arătat o recuperare parțială, cu un RMSE de 0,306 m² și un bias de 0,073 m², indicând faptul că, în medie, diferențele au fost mici, dar au existat și valori mai ridicate ale erorilor în aceste seturi de date. Cele mai înguste limite de concordanță (LoA) de 95% au fost observate în WI, unde valorile au variat între -0,199 și 0,082 m². Cele mai largi LoA de 95% au apărut în SP, unde valorile au variat între -0,861 și 0,492 m². Acest lucru sugerează o variabilitate mai mare a măsurătorilor în perioadele cu frunziș. Cu toate acestea, majoritatea valorilor s-au încadrat în limitele de 95% în toate sezoanele. Coeficienții de determinare ai reziduurilor au rămas scăzuți ($R^2_{\text{rez}} < 0,100$), confirmând absența unui bias proporțional semnificativ. Aceste rezultate oferă o bază cantitativă pentru evaluarea concordanței inter-platforme pe sezoane.




Figura 4.1. Diagrame Bland–Altman pentru concordanța suprafeței de bază (BA) la nivel de suprafață de probă în funcție de sezoanele fenologice (WI, SP, SU, AU).

Notă: Fiecare punct de date reprezintă suprafața de bază agregată a unei suprafețe circulare individuale ($n = 50$). Linia neagră continuă indică biasul mediu; liniile roșii întrerupte marchează limitele de concordanță de 95% (LoA). Linia portocalie reprezintă tendința liniară a reziduurilor, care a rămas scăzută pe întreaga gamă de măsurători ($R^2 < 0,100$).

4.2.3 Paritate statistică între platforme

Comparațiile statistice între estimările TreeScanner (BAA) și FJD Trion P1 (BAS) au evidențiat diferențe semnificative în Iarnă (WI), Primăvară (SP) și Vară (SU) ($p < 0,001$), în timp ce paritatea statistică a fost atinsă doar în Toamnă (AU) ($p = 0,093$) (Tabelul 4.3). În ceea ce privește dinamica intra-platformă, diferențele sezoniere ale suprafeței de bază la nivel de arboret au fost semnificative pentru ambele sisteme ($p < 0,05$). Datele TreeScanner au arătat o creștere graduală a BAA de la 1,38 m² (WI) la 1,75 m² (AU). În contrast, estimările FJD Trion P1 au prezentat o variabilitate sezonieră mai mare.

Tabelul 4.3. Paritate tehnică şi consistenţă operaţională (n = 50).

Variabilă	Pereche de comparație	Test statistic	p- valoare	Rezultat
Suprafață de bază	BAA_WI vs BAS_WI	Paired t-test	< 0.001	Diferență semnificativă
	BAA_SP vs BAS_SP	Paired t-test	< 0.001	Diferență semnificativă
	BAA_SU vs BAS_SU	Paired t-test	< 0.001	Diferență semnificativă
	BAA_AU vs BAS_AU	Paired t-test	= 0.093	Diferență ne semnificativă
Timp de achiziție	TA_WI vs TS_WI	Wilcoxon	< 0.001	Diferență semnificativă
	TA_SP vs TS_SP	Wilcoxon	< 0.001	Diferență semnificativă
	TA_SU vs TS_SU	Wilcoxon	< 0.001	Diferență semnificativă
	TA_AU vs TS_AU	Wilcoxon	< 0.001	Diferență semnificativă

Notă: NS se referă la diferențe ne semnificative ($p \geq 0,050$), indicând paritate statistică.

Timpul de achiziție a fost analizat separat pentru fiecare platformă. Rezultatele au arătat că TA per suprafață de probă utilizând TreeScanner a rămas relativ constant pe parcursul sezoanelor, fără diferențe semnificative față de valoarea de referință din WI (SP: $p = 0,197$; SU: $p = 0,180$; AU: $p = 0,194$). Valoarea medie TA a fost de aproximativ 16 secunde per arbore. În schimb, valorile TS per suprafață de probă obținute cu FJD Trion P1 au prezentat diferențe semnificative între sezoane ($p < 0,05$), cu valoarea maximă în SP (653,96 s) și minimă în AU (498,66 s). Valorile TA au rămas mai mici decât TS în toate sezoanele.

4.2.4 Corelația sezonieră a estimărilor suprafeței de bază TreeScanner și FJD Trion P1

Regresia liniară dintre estimările TreeScanner (BAA) și FJD Trion P1 (BAS) a arătat că relația variază în funcție de stadiul fenologic (Figura 4.3). În larnă (WI), coeficientul de determinare a fost cel mai ridicat ($R^2 = 0,974$), cu un coeficient de regresie de 0,937 și un termen liber redus (0,033). Primăvara (SP) a prezentat cea mai slabă ajustare ($R^2 = 0,530$; pantă = 0,645). Vara (SU) și Toamna (AU) au avut valori intermediare ale R^2 (0,719). Pantă în AU a fost cea mai apropiată de 1 (0,965), indicând cea mai bună corespondență cu linia de identitate.




Figura 4.2. Diagrame de dispersie şi regresie liniară pentru BAA vs BAS în funcţie de sezoanele fenologice. Notă: Linie întreruptă: identitatea teoretică ($y = x$); linie roşie continuă: regresia ajustată; zonă colorată: interval de încredere de 95%.

Benzile de încredere de 95% din Figura 4.2 sunt cele mai înguste în WI, reflectând R^2 ridicat, şi cele mai largi în SP. În SU şi AU prezintă valori intermediare. În AU, banda de încredere este apropiată de linia de identitate ($y = x$), în concordanţă cu panta regresiei.

4.3 CONCLUZII

Acest studiu arată că condiţiile fenologice influenţează nivelul de concordanţă dintre sistemele LiDAR pe smartphone şi PLS profesional în inventarierea forestieră, evidenţiat prin variaţii sezoniere de-a lungul ciclului fenologic. Interpretarea conform căreia prezenţa frunzişului este un factor important al variabilităţii sezoniere este susţinută de concordanţa cea mai ridicată între sistemul PLS profesional şi aplicaţia pe smartphone în condiţii de lipsă de frunziş şi senescentă. Deşi AU a prezentat cea mai mare concordanţă statistică între platforme, WI a oferit cele mai stabile condiţii de măsurare. În condiţii de teren, aplicaţia pe smartphone a prezentat o rată de achiziţie relativ stabilă şi constant mai rapidă comparativ cu aplicaţia profesională bazată pe SLAM. Totuşi, această comparaţie trebuie interpretată cu prudenţă din cauza diferenţelor dintre protocoalele de achiziţie utilizate în acest studiu. În condiţiile analizate, eficienţa a fost influenţată doar slab de panta terenului. Rezultatele sugerează că achiziţia bazată pe smartphone poate oferi avantaje de eficienţă pentru evaluări rapide la nivel de arboret în medii structural complexe şi terenuri cu topografie dificilă. Absenţa unui bias proporţional semnificativ indică faptul că erorile detectate sunt în principal independente de diametrul arborelui, ceea ce sugerează că erorile de măsurare sunt în mare parte independente de tehnica de măsurare în condiţii de vizibilitate bună. Concordanţa mai scăzută observată în SP evidenţiază importanţa alinierii campaniilor de inventariere cu perioadele fenologice cu interferenţă redusă a vegetaţiei. În concluzie, tehnologia LiDAR pe smartphone prezintă un potenţial considerabil pentru estimarea eficientă a suprafeţei de bază la nivel de arboret în condiţii favorabile. Cercetări suplimentare care includ mai multe date de validare şi teste în diferite tipuri de arborete ar putea îmbunătăţi robusteţea acestei metode.

CAPITOLUL 5. COMPARAREA NORILOR DE PUNCTE UTILIZÂND ALGORITMI C2C ŞI M3C2 ÎN ECOSISTEME FORESTIERE DIVERSE.

5.1 MATERIALE ŞI METODE

Studiul a fost realizat în ecosisteme forestiere situate între Braşov şi Poiana Braşov, România. Au fost amplasate cincizeci de suprafeţe de probă circulare cu o rază de 9,80 m pentru a surprinde variabilitatea compoziţiei speciilor, a structurii coronamentului şi a condiţiilor de teren. Centrele suprafeţelor de probă au fost georeferenţiate utilizând un receptor GPS Garmin GPSMAP 64sx, iar suprafeţele de probă au fost delimitate cu ajutorul unei rulete. Pădurile selectate au inclus specii precum fag (*Fagus sylvatica*), molid (*Picea abies*), brad (*Abies alba*), gorun (*Quercus petraea*), pin silvestru (*Pinus sylvestris*) şi carpen (*Carpinus betulus*), acoperind o gamă variată de structuri de arboret caracterizate prin diferenţe de vârstă, pantă, altitudine, acoperirea coronamentului şi densitatea arboretului.

Achiziţia datelor a fost realizată utilizând scannerul mobil laser FJD Trion P1, un sistem bazat pe SLAM, cu un câmp vizual de $360^\circ \times 59^\circ$, o rată de scanare de până la 200.000 de puncte pe secundă şi o precizie estimată de aproximativ 2 cm (FJDynamics, 2026). Fiecare suprafaţă de probă a fost scanată urmând o traiectorie eliptică standardizată, împărţită conceptual în patru cadrane, operatorul deplasându-se în jurul suprafeţei de probă menţinând scannerul orientat spre centru. Scanările s-au extins aproximativ 5 m dincolo de limitele suprafeţei de probă pentru a asigura o acoperire spaţială completă. Datele au fost colectate în cadrul a două campanii de teren reprezentând condiţiile de iarnă (decembrie 2024) şi primăvară (mai 2025).

Procesarea norilor de puncte a fost realizată în CloudCompare. Norii de puncte din iarnă au fost utilizaţi ca set de referinţă şi au fost aliniaţi cu datele de primăvară prin înregistrare fină de tip Iterative Closest Point (ICP). Ambele seturi de date au fost apoi decupate utilizând o limită cilindrică de 10 m pentru a asigura o extindere spaţială identică, urmată de eliminarea zgomotului prin filtrul Statistical Outlier Removal (SOR). Acest proces a generat nori de puncte curaţi şi spaţial consistenti pentru comparaţie. Au fost utilizate două metode complementare pentru cuantificarea diferenţelor sezoniere: analiza Cloud-to-Cloud (C2C), care calculează diferenţele dintre puncte pe baza celui mai apropiat vecin, şi analiza Multiscale Model-to-Model Cloud Comparison (M3C2), care estimează distanţele de-a lungul normalelor locale ale suprafeţei şi ia în considerare structura şi densitatea norului de puncte (Lague et al., 2013).

Metoda C2C a furnizat indicatori precum distanţa medie, abaterea standard, RMSE, acoperirea şi distribuţia distanţelor, pe baza căutărilor de tip k-d tree pentru cel mai apropiat vecin. Metoda M3C2 a furnizat indicatori analogi, dar integrând orientarea suprafeţei şi parametri de scară locală, îmbunătăţind robusteţea la zgomot şi variaţii ale densităţii punctelor. Împreună, cele două metode au permis o evaluare cantitativă a schimbărilor sezoniere în structura forestieră pe baza datelor LiDAR mobile, combinând abordări de comparaţie punct-la-punct şi suprafaţă-la-suprafaţă.

Analiza statistică a fost realizată în Microsoft Excel utilizând extensia Real Statistics. Au fost calculate statistici descriptive (medie, mediană, abatere standard, amplitudine de variaţie) pentru toţi indicatorii principali, iar normalitatea datelor a fost testată utilizând testul Shapiro–Wilk.




Figura 5.1. Descrierea fluxului de lucru pentru compararea norilor de puncte.

5.2 REZULTATE

5.2.1 Comparație Cloud-to-Cloud (C2C)

Rezultatele comparației Cloud-to-Cloud (C2C) sunt sintetizate în Tabelul 2. Distanța medie dintre norii de puncte din iarnă și primăvară a fost de 0,091 m, cu o abatere standard a distanțelor de 0,027 m. Acest lucru indică faptul că punctele au fost bine aliniate. Abaterea standard a distanțelor, un indicator al variabilității distanțelor dintre puncte, a fost în medie 0,115 m, cu o valoare maximă a abaterii standard de 0,038 m. Acest lucru indică existența unor variații locale în geometria norului de puncte. Acoperirea a fost de asemenea de 100%, indicând faptul că întreaga zonă de studiu a fost reprezentată corespunzător. RMSE pentru alinierea norilor de puncte a fost în medie 0,147 m, reprezentând un indicator al magnitudinii deviației dintre cei doi nori de puncte. Rezultatele oferă o imagine generală a schimbărilor dintre norii de puncte de iarnă și primăvară, indicând variații reduse.

Tabelul 5.1. Statistici sintetice ale comparației C2C a norilor de puncte

Parametru	Medie $\pm$ abatere standard	Valoare minimă	Valoare maximă	Amplitudine de variație
Distanță (m) ¹	0.091 $\pm$ 0.027	0.036	0.201	0.165
Abaterea standard a distanței (m) ¹	0.115 $\pm$ 0.038	0.051	0.290	0.239
Acoperire (%) ¹	100.0 $\pm$ 0.0	100.0	100.0	0.000
RMSE al alinierii norilor de puncte (m) ¹	0.147 $\pm$ 0.045	0.063	0.353	0.290

Notă: ¹ – variabilă pentru care a fost încălcată ipoteza de normalitate.

Toate punctele centrale (CP) și punctele valide (VP) au fost utilizate în analiza C2C, cu valori identice pentru ambii parametri în toate suprafețele de probă, variind între aproximativ 11,6 și 23,2 milioane de puncte. Valorile mediane pentru distanță, abaterea standard, acoperire și RMSE au fost ușor mai mici decât valorile medii (vezi Tabelul 5.2).

5.2.2 Comparație Model-to-Model Cloud (M3C2)

Rezultatele comparației Multiscale Model-to-Model Cloud Comparison (M3C2) sunt sintetizate în Tabelul 5.3. Distanța medie dintre norii de puncte din iarnă și primăvară a fost de -0,004 m, cu o abatere standard de 0,035 m, indicând faptul că, în medie, nu a fost înregistrată o deplasare sistematică între cele două

seturi de date. Abaterea standard a distanţelor a arătat însă o variabilitate mai mare, cu o valoare medie de 0,295 m şi o abatere standard de 0,070 m, reprezentând variaţii locale ale geometriei suprafeţei. Acoperirea a fost ridicată în toate suprafeţele de probă, cu o medie de 98,41%, indicând că majoritatea suprafeţei suprafeţelor de probă a fost inclusă în analiză. RMSE a avut o valoare medie de 0,297 m, indicând nivelul general al diferenţelor dintre cei doi nori de puncte. În ansamblu, rezultatele indică modificări medii reduse, dar o variabilitate locală existentă.

Tabelul 5.3. Statistici sintetice ale comparaţiei M3C2 a norilor de puncte.

Parametru	Medie $\pm$ abatere standard	Valoare minimă	Valoare maximă	Amplitudine de variaţie
Distanţă (m) ¹	-0.004 $\pm$ 0.035	0.151	0.435	0.284
Abaterea standard a distanţei (m)	0.295 $\pm$ 0.070	0.151	0.435	0.283
Acoperire (%) ¹	98.41 $\pm$ 1.448	92.56	99.90	7.34
RMSE al alinierii norilor de puncte (m)	0.297 $\pm$ 0.071	0.063	0.353	0.290

Notă: ¹ – variabilă pentru care a fost încălcată ipoteza de normalitate.

Punctele centrale (CP) şi punctele valide (VP) utilizate în comparaţia M3C2 au variat între aproximativ 9,57 şi 22,57 milioane de puncte (CP) şi între aproximativ 9,56 şi 21,95 milioane de puncte (VP) în seturile de date. Valorile mediane pentru distanţă şi acoperire au fost -0,0036 m şi, respectiv, 98,83% (vezi Tabelul 5.3).

5.3 CONCLUZII

Cele două metode, C2C şi M3C2, sunt consistente în compararea norilor de puncte obţinuţi în sezoane diferite, permiţând evaluarea schimbărilor structurale din ecosistemele forestiere. Metoda C2C oferă o reprezentare generală şi uniformă a norului de puncte, în timp ce M3C2 surprinde în detaliu variaţiile locale. Se poate concluziona că alegerea metodei depinde de obiectivul analizei. Densitatea punctelor, ocluzia şi zgomotul influenţează acurateţea metricilor de comparaţie. Este evident că metoda M3C2 este mai robustă faţă de aceşti factori. Unele limitări ale studiului includ aplicabilitatea sa la un număr restrâns de ecosisteme forestiere şi la doar două sezoane. Se recomandă extinderea analizei la alte ecosisteme şi sezoane. Rezultatele oferă o bază metodologică pentru selecţia tehnicilor de comparaţie în inventare forestiere multi-temporale, contribuind la îmbunătăţirea fiabilităţii monitorizării structurii forestiere.

CAPITOLUL 6. CONCLUZII. CONTRIBUȚII ORIGINALE. DISEMINAREA REZULTATELOR

6.1. CONCLUZII

Această teză a avut ca scop explorarea potențialului tehnologiilor LiDAR portabile și mobile, inclusiv al aplicațiilor bazate pe smartphone, pentru inventarierea forestieră. Lucrarea s-a bazat pe o analiză a stadiului actual al cunoașterii și pe o serie de studii experimentale care au evaluat acuratețea și eficiența acestor tehnologii în diverse condiții forestiere. De asemenea, a fost analizată capacitatea lor de a completa sau chiar de a înlocui metodele tradiționale de teren. Principalele concluzii sunt prezentate mai jos, organizate în funcție de obiectivele specifice ale tezei:

1. Revizuirea tehnologiilor LiDAR mobile și cu cost redus pentru inventarele forestiere (O1): Aceste instrumente sunt într-o dezvoltare rapidă și combină precizia cu eficiența. Tehnologiile emergente, precum aplicațiile bazate pe smartphone, pot schimba modul de colectare a datelor în teren. Ele permit o monitorizare forestieră mai rapidă și mai accesibilă, în special în contexte cu resurse limitate.

2. Acuratețea aplicației TreeScanner în estimarea parametrilor biometrici la nivel de arbore (O2): Aplicația TreeScanner s-a dovedit precisă în estimarea diametrului la înălțimea pieptului (DBH) și a înălțimii arborilor în diferite ecosisteme forestiere, prezentând erori reduse. Acest lucru validează utilizarea sa pentru realizarea inventarelor la nivel de arbore, în situațiile în care viteza și simplitatea sunt importante.

3. Compararea aplicației mobile și a sistemelor LiDAR profesionale din perspectiva eficienței temporale și a estimării suprafeței de bază (O3): Aplicația mobilă a redus semnificativ timpul necesar colectării datelor în teren comparativ cu metodele convenționale și, în multe cazuri, a depășit performanțele sistemelor LiDAR profesionale, în special pentru estimarea suprafeței de bază. Acest avantaj temporal este esențial în terenuri complexe sau atunci când sunt necesare inventare rapide.

4. Efectul variației sezoniere asupra estimării suprafeței de bază (O4): Condițiile sezoniere au influențat acuratețea estimărilor suprafeței de bază. Cele mai bune rezultate au fost obținute în perioadele fără frunziș (iarnă), când vizibilitatea trunchiurilor a fost optimă. În perioadele cu frunziș (primăvara), măsurătorile au fost influențate de acoperirea coronamentului și densitatea vegetației, deși aplicația a continuat să ofere estimări fiabile.

5. Compararea norilor de puncte utilizând metodele C2C și M3C2 (O5): Ambele metode s-au dovedit utile pentru detectarea diferențelor structurale dintre norii de puncte obținuți cu sisteme LiDAR mobile și profesionale. Metoda M3C2 a oferit rezultate mai stabile în condiții complexe, în timp ce metoda C2C a fost mai potrivită pentru obținerea unor imagini generale asupra structurii. Aceste metode au aplicații complementare, în funcție de nivelul de detaliu necesar.

În concluzie, această teză demonstrează că tehnologiile LiDAR portabile și mobile, inclusiv LiDAR-ul bazat pe smartphone, reprezintă un instrument promițător și viabil pentru îmbunătățirea inventarelor forestiere. Aceste tehnologii oferă un echilibru favorabil între acuratețe, eficiență și costuri. Cu toate acestea, este important să fie luate în considerare limitările lor, precum dependența de condițiile de teren și variabilitatea sezonieră. Cercetările viitoare ar putea viza îmbunătățirea acurateței în medii cu vegetație densă și integrarea acestor sisteme cu alte platforme tehnologice, precum dronele și sateliții, pentru a depăși limitările actuale și a extinde aplicabilitatea lor în diferite contexte forestiere.

6.2. CONTRIBUȚII ORIGINALE

Contribuțiile originale ale acestei lucrări se concentrează asupra modului în care tehnologiile LiDAR mobile pot completa sau chiar înlocui metodele tradiționale de măsurare în teren, îmbunătățind atât acuratețea datelor, cât și eficiența operațională în managementul forestier. Pe parcursul celor cinci capitole care alcătuiesc această teză, sunt abordate teme ce variază de la evaluări comparative între sisteme LiDAR mobile și senzori profesionali, până la analiza impactului condițiilor fenologice asupra măsurătorilor, incluzând validarea aplicațiilor mobile pentru estimarea parametrilor dendrometrici. Contribuțiile fiecărui capitol sunt detaliate mai jos, urmate de o discuție privind limitările lucrării și direcțiile viitoare de cercetare necesare pentru avansarea în acest domeniu.

Capitolul 1 – Revizuirea şi evaluarea tehnologiilor LiDAR mobile şi cu cost redus pentru inventarele forestiere:

Principala contribuţie a acestui capitol constă în sintetizarea progreselor recente privind utilizarea LiDAR-ului mobil în inventarele forestiere, cu un accent special pe compararea tehnologiilor cu cost redus cu senzorii profesionali. Deşi aceste subiecte au fost abordate anterior de alţi autori, integrarea şi analiza lor comparativă nu au fost realizate până în prezent. Cercetarea demonstrează că utilizarea echipamentelor mobile cu LiDAR integrat (de exemplu, smartphone-uri) oferă un nivel similar de fiabilitate tehnică comparativ cu metodele tradiţionale, având însă avantajul reducerii semnificative a timpului necesar măsurărilor în teren. În plus, studiul analizează efectele fenologiei asupra preciziei măsurărilor şi concluzionează că perioada fără frunziş reprezintă momentul optim pentru efectuarea măsurărilor. Contribuţia evidenţiază, de asemenea, importanţa aplicaţiilor mobile cu capacităţi de procesare instantanee, care facilitează luarea deciziilor direct în teren şi elimină barierele logistice asociate post-procesării datelor. În final, este propusă necesitatea adoptării unor fluxuri de lucru hibride care să integreze LiDAR-ul mobil cu alte sisteme aeriene pentru o acoperire forestieră mai completă, sugerând că aceste tehnologii au atins un nivel de maturitate capabil să transforme inventarele forestiere într-o infrastructură digitală mai accesibilă şi scalabilă.

Capitolul 2 – Evaluarea acurateţii aplicaţiei TreeScanner în diverse ecosisteme forestiere:

Acest studiu reprezintă o contribuţie originală prin furnizarea de dovezi empirice conform cărora aplicaţia TreeScanner poate oferi măsurători precise ale diametrului la înălţimea pieptului (DBH) şi ale înălţimii arborilor în diverse ecosisteme forestiere, cu un grad ridicat de concordanţă faţă de metodele convenţionale. Rezultatele arată că aplicaţia poate măsura DBH-ul cu precizie subcentimetrică şi înălţimea arborilor cu precizie submetrică, ceea ce reprezintă un progres important, deoarece aplicaţiile mobile LiDAR nu au fost considerate anterior suficient de precise pentru realizarea unor astfel de măsurători detaliate. Studiul oferă o validare empirică a posibilităţii utilizării dispozitivelor mobile pentru captarea precisă a variabilităţii inerente măsurărilor convenţionale şi propune o alternativă mai accesibilă şi economică pentru colectarea datelor în teren. De asemenea, evidenţiază importanţa desfăşurării unor cercetări suplimentare privind aplicarea acestei tehnologii în diferite tipuri de păduri, în special în cele cu densitate ridicată.

Capitolul 3 – Evaluarea acurateţii şi eficienţei temporale a aplicaţiei mobile pentru estimarea suprafeţei de bază:

Contribuţia acestui capitol este semnificativă prin demonstrarea faptului că aplicaţiile mobile LiDAR, precum cea testată în acest studiu, pot furniza estimări precise ale suprafeţei de bază la nivel de parcelă, cu o eficienţă temporală considerabil îmbunătăţită. Comparativ cu sistemele profesionale, aplicaţia mobilă a evidenţiat o reducere semnificativă a timpului de măsurare per arbore, ceea ce implică o creştere a eficienţei operaţionale şi o reducere a costurilor inventarelor forestiere. Deşi aplicaţia a demonstrat performanţe remarcabile, au fost identificate şi aspecte care necesită îmbunătăţiri, în special integrarea unor parametri suplimentari şi extinderea validării sale într-o varietate mai mare de ecosisteme forestiere. Această contribuţie nu doar demonstrează modul în care aplicaţiile mobile pot completa metodele tradiţionale, ci evidenţiază şi potenţialul acestor tehnologii de a oferi alternative mai economice şi accesibile pentru monitorizarea forestieră.

Capitolul 4 – Efectul variaţiei sezoniere asupra estimărilor suprafeţei de bază utilizând LiDAR mobil:

Acest capitol aduce o contribuţie inovatoare prin demonstrarea faptului că factorii fenologici, în special prezenţa sau absenţa frunzişului, joacă un rol important în determinarea eficienţei şi preciziei procesului de măsurare utilizând tehnologii LiDAR mobile. Rezultatele arată că LiDAR-ul mobil este mai eficient şi mai precis în perioada fără frunziş. Capitolul subliniază importanţa luării în considerare a fenologiei în planificarea inventarelor forestiere. Cercetarea sugerează, de asemenea, posibilitatea ca LiDAR-ul mobil să aibă aplicaţii practice în medii dificile, precum pădurile montane, în contrast cu măsurătorile tradiţionale, care sunt mai puţin eficiente în astfel de condiţii. În plus, au fost identificate perioadele optime pentru realizarea inventarelor, ceea ce poate optimiza timpul de lucru şi calitatea datelor colectate în diferite condiţii.

Capitolul 5 – Compararea metodelor C2C și M3C2 pentru norii de puncte în monitorizarea forestieră multitemporală:

Acest capitol prezintă o contribuție metodologică importantă prin realizarea unei comparații detaliate între metodele C2C și M3C2 în contextul monitorizării forestiere multitemporale. Cercetarea arată că, în timp ce metoda C2C oferă o imagine de ansamblu mai uniformă asupra norului de puncte, metoda M3C2 permite o reprezentare mai detaliată a variațiilor locale ale structurii forestiere. Acest aspect este deosebit de important din punct de vedere practic, deoarece poate fi necesar ca administratorii forestieri să aleagă una dintre aceste metode în funcție de obiectivele monitorizării forestiere. În plus, sunt analizate efectele densității punctelor, ocluziei și zgomotului asupra acurateței rezultatelor, ceea ce contribuie la creșterea fiabilității monitorizării multi-temporale în diverse condiții forestiere. Această contribuție nu doar îmbunătățește înțelegerea tehnicilor de comparare a norilor de puncte, ci oferă și o bază metodologică pentru creșterea fiabilității inventarelor forestiere în timp.

Limitări și direcții viitoare de cercetare

În ciuda contribuțiilor acestei teze, există anumite limitări care trebuie evidențiate. Studiile au fost realizate într-un număr limitat de ecosisteme și în condiții specifice, ceea ce restrânge posibilitatea generalizării rezultatelor la alte zone. De asemenea, măsurătorile efectuate în terenuri complexe sau în păduri dense prezintă în continuare provocări care necesită cercetări suplimentare. Direcțiile viitoare de cercetare includ extinderea testărilor în teren ale tehnologiilor LiDAR mobile în diverse tipuri de păduri și în diferite condiții fenologice, precum și integrarea unor tehnologii noi, precum inteligența artificială, în proces.

6.3. DISEMINAREA REZULTATELOR

6.3.1. Publicații științifice bazate pe această teză de doctorat

A. Articole publicate în reviste indexate BDI

1. **Morocho Toaza, J. M.** (2026). Low-cost and mobile LiDAR technologies for forest inventory: A review on accuracy, efficiency, and multi-temporal monitoring potential. Acceptat spre publicare la Bulletin of the Transilvania University of Brasov. Series II: Forestry• Wood Industry• Agricultural Food Engineering. (in review). Revistă indexată în baza de date Scopus.
2. **Morocho Toaza, J. M.** (2026). Comparing point clouds using C2C and M3C2 algorithms in diverse forest ecosystems. Trimis spre publicare la *Revista Pădurilor* (în evaluare). Revistă indexată în CABI și RePEc.

B. Articole publicate în reviste indexate Clarivate Analytics (fost ISI Web of Science)

1. **Morocho Toaza, J. M.**, Picchi, G., Nati, C., Borz, S. A. (2025). Accuracy and time efficiency of a new app developed to source and map single-tree data: a comparison to state-of-the-art lidar data collectors in terms of basal area estimates. *Ecological Informatics* 91. 103417. DOI: <https://doi.org/10.1016/j.ecoinf.2025.103417>. *Ecological Informatics* este o revistă peer-reviewed, clasificată Q1 și indexată în Web of Science. Link la Web of Science <https://www.webofscience.com/wos/woscc/full-record/WOS:001567319900001>
2. **Morocho Toaza, J. M.**, Elias, M., Alfaro, V. D. S., Naiman, D. E., Musca, C. D., Picchi, G., Nati, C., Forkuo, G. O., Borz, S. A. (2026). Accuracy of tree scanner app in sourcing tree-level biometrics: A case study based on data from diverse forest ecosystems. Trimis spre publicare la *Annals of Forest Research* (în evaluare). *Annals of Forest Research* este o revistă peer-reviewed, clasificată Q1 și indexată în Web of Science.
3. **Morocho Toaza, J. M.**, Borz, S. A. (2026). Seasonal performance in basal area estimation: A comparative study of a smartphone lidar application and a professional personal laser scanning. *Frontiers in Forests and Global Change* 9. 1844787. DOI: <https://doi.org/10.3389/ffgc.2026.1844787>. *Frontiers in Forests and Global Change* este o revistă peer-reviewed, clasificată Q1 și indexată în Web of Science.

6.3.2. Lucrări prezentate la conferinţe ştiinţifice bazate pe această teză de doctorat

A. Lucrări prezentate la conferinţe ştiinţifice naţionale

1. **Morocho Toaza, J. M.**, Borz, S.A., 2024. Applications of LIDAR, UAV Remote Sensing and Digital Twinning Technologies in Forest Engineering. Graduates in Front of Companies (AFCO) 2024. Contribuţie prezentată la conferinţă naţională. Disponibil online la: https://afco.unitbv.ro/2024/images/Documente/AFCO_2024_Lucrari_inscrise_.pdf
2. **Morocho Toaza, J. M.**, Borz, S.A., 2024. Applications of LIDAR, UAV Remote Sensing and Digital Twinning Technologies in Forest Engineering. DoCo2024. Prezentare în cadrul unei conferinţe academice naţionale. Disponibil online la: <https://www.unitbv.ro/en/research/doctoral-studies/2024-doctoral-conference.html>. Conference program details are available online at: https://www.unitbv.ro/Detailed_Programme.pdf

B. Lucrări prezentate la conferinţe ştiinţifice internaţionale

1. **Morocho Toaza, J. M.**, Borz, S.A., Elias, M., Forkuo, G.O., Picchi, G., Nati, C. (2025). DIGIFOR – A project setup to collect and document multi-temporal plot-level LiDAR data. Book of Abstracts: Proceedings of the 57th International Symposium of Forest Mechanization (FORMEC), Finland Contribuţie prezentată în cadrul unui simpozion internaţional. Disponibil online la: <https://erepo.uef.fi/server/api/core/bitstreams/2dd5580c-e499-4590-a04f-aebea21969d4/content>